

TESIS - PM 092315

# **PEMODELAN BOX-JENKINS (ARIMA) UNTUK PERAMALAN INDEKS HARGA SAHAM GABUNGAN**

VINCENTIUS IWAN PRIMADITYA  
NRP. 9110205441

Dosen Pembimbing  
Prof. Drs. Nur Iriawan, M.IKom., Ph.D.

MAGISTER MANAJEMEN TEKNOLOGI  
BIDANG KEAHLIAN MANAJEMEN TEKNOLOGI INFORMASI  
PROGRAM PASCASARJANA  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2014

THESIS - PM 092315

# **BOX-JENKINS (ARIMA) MODELING FOR FORECASTING THE JAKARTA COMPOSITE INDEX**

VINCENTIUS IWAN PRIMADITYA  
NRP. 9110205441

Supervisor  
Prof. Drs. Nur Iriawan, M.IKom., Ph.D.

MASTER IN TECHNOLOGY MANAGEMENT  
INFORMATION TECHNOLOGY MANAGEMENT CONCENTRATION  
POSTGRADUATE PROGRAMME  
TENTH OF NOVEMBER INSTITUTE OF TECHNOLOGY  
SURABAYA  
2014

**Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar  
Magister Manajemen Teknologi (M.MT)  
di  
Institut Teknologi Sepuluh Nopember  
Oleh**

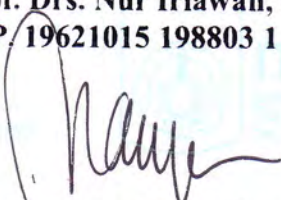
**Vincentius Iwan Primaditya  
NRP. 9110205441**

**Tanggal Ujian : 16 Januari 2015  
Periode Wisuda: Maret 2015**


**Disetujui oleh :**

  
**Prof. Drs. Nur Iriawan, M.IKom., Ph.D.  
NIP. 19621015 198803 1 002**

**(Dosen Pembimbing)**

  
**Dr. Ir. Raden Venantius Hari Ginardi, M.Sc.  
NIP. 19650518 199203 1 003**

**(Dosen Penguji I)**

  
**Dr. Vita Ratnasari, S.Si., M.Si.  
NIP. 19700910 199702 2 001**

**(Dosen Penguji II)**

**Direktur Program Pascasarjana**



**Prof. Dr. Ir. Adi Soeprijanto, M.T.  
NIP. 19640405 199002 1 001**

# **PEMODELAN BOX-JENKINS (ARIMA) UNTUK PERAMALAN INDEKS HARGA SAHAM GABUNGAN**

Nama : Vincentius Iwan Primaditya  
NRP : 9110205441  
Pembimbing : Prof. Drs. Nur Iriawan, M.IKom., Ph.D.

## **ABSTRAK**

Indeks Harga Saham Gabungan (IHSG) merupakan indikator utama yang digunakan di Bursa Efek Indonesia (BEI) untuk mengukur kinerja pasar saham secara keseluruhan. Peramalan yang akurat mengenai pergerakan indeks dapat menghasilkan keuntungan bagi investor dan untuk mengembangkan strategi perdagangan pasar saham yang efektif. *Autoregressive Integrated Moving Average* (ARIMA) adalah model deret waktu yang berguna untuk peramalan indeks harga saham dengan menggunakan autokorelasi dan variasi residual deret waktu. Masing-masing tahap dalam pemodelan Box-Jenkins dilakukan dan menghasilkan model ARIMA(3,1,2). Jumlah lag autoregresi yang dihasilkan kemudian digunakan sebagai *input* ke dalam sistem Jaringan Syaraf Tiruan (JST) untuk menghasilkan model prediksi *Neural Network Autoregression* (NAR). Untuk mengetahui apakah pasar saham di BEI sesuai dengan hipotesis pasar efisien bentuk lemah, maka peramalan dengan model *Random Walk with Drift* juga dilakukan. Hasil evaluasi akurasi peramalan ketiga model pada dataset *testing* menggunakan *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) menunjukkan bahwa NAR(3) menghasilkan kesalahan peramalan terkecil dengan akurasi yang berada dalam kisaran 98%. Hasil penelitian keseluruhan memberikan indikasi bahwa pasar saham di BEI tidak sesuai dengan hipotesis pasar efisien bentuk lemah.

**Kata Kunci:** arima, autokorelasi, box-jenkins, indeks harga saham gabungan, peramalan, prediksi, *random walk*.

# **BOX-JENKINS (ARIMA) MODELING FOR FORECASTING THE JAKARTA COMPOSITE INDEX**

Name : Vincentius Iwan Primaditya  
NRP : 9110205441  
Supervisor : Prof. Drs. Nur Iriawan, M.IKom., Ph.D.

## **ABSTRACT**

The Jakarta Composite Index (JCI) is the main indicator used in the Indonesia Stock Exchange (IDX) to measure the overall performance of the stock market. Accurate forecasting of the movement of the index would benefit investors and to develop strategies for effective stock market trading. Autoregressive Integrated Moving Average (ARIMA) time series model is useful for forecasting stock price index by using autocorrelation and residual variation in the time series. Each stage in the Box-Jenkins modeling were performed and produced ARIMA (3,1,2). The order of lag of the autoregression generated is then used as input to an Artificial Neural Network (ANN) system to generate a predictive model Neural Network Autoregression (NAR). To determine whether the IDX stock market is in accordance with the weak form of the efficient-market hypothesis, the Random Walk with Drift forecasting model was also performed. Forecasting accuracy evaluation of the three models on testing dataset using the Mean Absolute Error (MAE), Root Mean Squared Error (RMSE) and Mean Absolute Percentage Error (MAPE) indicates that the NAR (3) generates the smallest forecasting error with accuracy within the range of 98%. Overall study results provide an indication that the IDX is not in accordance with the weak form of the efficient-market hypothesis.

**Keywords:** arima, autoregression, box-jenkins, jakarta composite index, forecasting, prediction, *random walk*.

**Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar  
Magister Manajemen Teknologi (M.MT)  
di  
Institut Teknologi Sepuluh Nopember  
Oleh**

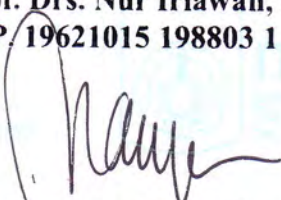
**Vincentius Iwan Primaditya  
NRP. 9110205441**

**Tanggal Ujian : 16 Januari 2015  
Periode Wisuda: Maret 2015**


**Disetujui oleh :**

  
**Prof. Drs. Nur Iriawan, M.IKom., Ph.D.  
NIP. 19621015 198803 1 002**

**(Dosen Pembimbing)**

  
**Dr. Ir. Raden Venantius Hari Ginardi, M.Sc.  
NIP. 19650518 199203 1 003**

**(Dosen Penguji I)**

  
**Dr. Vita Ratnasari, S.Si., M.Si.  
NIP. 19700910 199702 2 001**

**(Dosen Penguji II)**

**Direktur Program Pascasarjana**



**Prof. Dr. Ir. Adi Soeprijanto, M.T.  
NIP. 19640405 199002 1 001**

## KATA PENGANTAR

Dengan segenap rasa syukur kehadiran Tuhan Yesus Kristus dan Bunda Maria, penulis mendapat kesempatan studi dan telah dapat menyelesaikan tesis untuk memenuhi salah satu syarat memperoleh gelar Magister Manajemen Teknologi (M.MT) di Institut Teknologi Sepuluh Nopember Surabaya (ITS).

Dalam penyusunan tesis ini penulis mengambil judul PEMODELAN BOX-JENKINS (ARIMA) UNTUK PERAMALAN INDEKS HARGA SAHAM GABUNGAN.

Dalam kesempatan ini penulis ingin menyampaikan terima kasih kepada:

1. Bapak Prof. Drs. Nur Iriawan, M.IKom., Ph.D. selaku pembimbing.
2. Bapak Dr. Ir. Raden Venantius Hari Ginardi, M.Sc. selaku penguji.
3. Ibu Dr. Vita Ratnasari, S.Si., M.Si. selaku penguji.
4. Bapak Prof. Putu Wiguna, Bapak Dr. Sony Sunaryo, Bapak F.A. Handoko Sasmito, MBA dan Ibu Prof. Yulinah Trihadiningrum, selaku dosen pengajar.
5. Segenap staf dan teman-teman MMT-ITS.
6. Ayah dan Bunda tercinta yang pantang menyerah memberikan arahan dan dukungan baik moral maupun material selama melakukan studi di ITS.
7. Adik tercinta Ignatius Hananto Herlambang, M.Phil. yang selalu memberikan motivasi dan pencerahan.
8. Ade, Dedy, Leo, Lia, Luh Putri, Oni, Wisnu, yang selalu memberi dukungan dan saran kepada penulis.

Ucapan terima kasih juga penulis sampaikan untuk semua pihak yang tidak dapat penulis sebutkan satu per satu dalam tulisan ini.

Semoga Tuhan memberikan berkat dan rahmat-Nya kepada semua pihak yang telah turut serta membantu memberikan dukungan atas terselesaikannya penulisan tesis ini.

Penulis sadar bahwa masih banyak kekurangan dalam penulisan tesis ini. Untuk itu saran dan kritik yang sifatnya membangun sangat diharapkan demi perbaikan sehingga dapat bermanfaat bagi pembaca semua.

Surabaya, Januari 2015

Penulis



## DAFTAR ISI

Halaman Depan.....	i
Lembar Pengesahan.....	ii
Abstrak.....	iii
Abstract.....	iv
Kata Pengantar.....	v
Daftar Isi.....	vi
Daftar Tabel.....	ix
Daftar Gambar.....	x
Daftar Lampiran.....	xi
 BAB 1 PENDAHULUAN .....	 1
1.1 Latar Belakang.....	1
1.2 Perumusan Masalah.....	3
1.3 Tujuan.....	4
1.4 Kontribusi .....	4
1.5 Manfaat.....	4
1.6 Batasan Masalah.....	5
1.7 Sistematika Penulisan.....	5
 BAB 2 TINJAUAN PUSTAKA DAN DASAR TEORI .....	 7
2.1 Hipotesis Pasar-Efisien.....	7
2.2 Penelitian Sebelumnya .....	9
2.3 Indeks Harga Saham.....	10
2.4 Analisis Teknikal.....	11
2.5 Analisis Deret Waktu .....	12
2.5.1 Definisi Deret Waktu.....	12
2.5.2 Stasioneritas Deret Waktu .....	13
2.5.3 Backshift Operator.....	13
2.5.4 Diferensiasi.....	13

2.5.5 Transformasi Box-Cox .....	14
2.5.6 Uji <i>Augmented</i> Dickey-Fuller (ADF) .....	14
2.5.7 Fungsi Autokorelasi dan Autokorelasi Parsial .....	15
2.5.8 Autoregressive Moving Average (ARMA) .....	15
2.5.9 Identifikasi ARMA .....	16
2.5.10 Deret Waktu Nonstasioner .....	17
2.5.11 Random Walk .....	17
2.5.12 Random Walk with Drift .....	17
2.5.13 Autoregressive Integrated Moving Average (ARIMA) .....	18
2.6 Pemodelan Box-Jenkins .....	19
2.7 Jaringan Syaraf Tiruan .....	20
2.7.1 Multilayer Feed-forward Neural Network .....	20
2.7.2 Algoritma Backpropagation .....	22
2.8 Neural Network Autoregression (NAR) .....	24
 BAB 3 METODE PENELITIAN .....	 27
3.1 Diagram Alir Penelitian .....	27
3.2 Data dan Variabel Penelitian .....	28
3.3 Pengolahan Data .....	28
3.4 Pemodelan Box-Jenkins .....	28
3.4.1 Tahap Identifikasi .....	29
3.4.2 Tahap Estimasi .....	29
3.4.3 Tahap Diagnostik .....	30
3.4.3.1 Uji Signifikansi Parameter .....	30
3.4.3.2 Uji Asumsi <i>White Noise</i> Residual .....	31
3.4.3.3 Uji Normalitas Residual .....	31
3.5 Peramalan Random Walk with Drift .....	32
3.6 Peramalan ARIMA .....	32
3.7 Pemodelan Neural Network Autoregression (NAR) .....	33
3.8 Evaluasi Akurasi Peramalan .....	34
3.9 Perangkat Lunak Yang Digunakan .....	34

BAB 4 HASIL DAN PEMBAHASAN.....	35
4.1 Pergerakan Indeks Harga Saham Gabungan .....	35
4.2 Statistik Deskriptif.....	35
4.3 Fungsi Autokorelasi.....	36
4.4 Uji <i>Augmented</i> Dickey-Fuller.....	36
4.5 Transformasi Box-Cox .....	36
4.6 Diferensiasi Deret Waktu .....	37
4.7 Identifikasi Fungsi Autokorelasi dan Autokorelasi Parsial .....	38
4.8 Estimasi Model.....	38
4.8.1 Uji Signifikansi Parameter .....	39
4.8.2.1 Uji Stasioneritas Residual.....	40
4.8.2.2 Uji Asumsi <i>White Noise</i> Residual .....	40
4.8.2.3 Uji Normalitas Residual .....	40
4.9 Peramalan <i>Random Walk</i> .....	41
4.10 Peramalan ARIMA(3,1,2) .....	41
4.11 Model Neural Network Autoregression .....	42
4.11.1 Uji Signifikansi Parameter .....	43
4.11.2 Diagnostik Residual.....	44
4.11.3 Uji Stasioneritas Residual.....	44
4.11.4 Uji Asumsi <i>White Noise</i> Residual .....	44
4.12 Peramalan NAR(3) .....	45
4.13 Evaluasi Akurasi Peramalan.....	45
BAB 5 KESIMPULAN DAN SARAN.....	47
5.1 Kesimpulan.....	47
5.2 Saran.....	48
DAFTAR PUSTAKA.....	49
LAMPIRAN.....	51

## DAFTAR TABEL

Tabel 2.1 Karakteristik ACF dan PACF proses ARMA.....	16
Tabel 2.2 Beberapa proses deret waktu dalam bentuk ARIMA.....	18
Tabel 3.1 Paket R yang digunakan.....	34
Tabel 4.1 Statistik Deskriptif IHSG Periode Januari 2010 - September 2014.....	35
Tabel 4.2 Hasil Uji Signifikansi Parameter model ARIMA(3,1,2).....	39
Tabel 4.3 Bobot Unit dalam Lapisan Tersembunyi.....	43
Tabel 4.4 Bobot Unit <i>Output</i> .....	43
Tabel 4.7. Hasil Evaluasi Akurasi Peramalan.....	45

## DAFTAR GAMBAR

Gambar 2.1 Diagram Alir Pemodelan Box-Jenkins .....	19
Gambar 2.2 <i>Multilayer Feed-forward Neural Network</i> .....	20
Gambar 2.3 Neuron Tiruan Tunggal .....	21
Gambar 2.4 Fungsi Aktivasi Sigmoid .....	21

# **BAB 1**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Bursa Efek Indonesia (BEI) telah mengalami pertumbuhan yang luar biasa sebagai pasar berkembang. Perkembangan BEI ditandai dengan volatilitas pasar yang tinggi. Volatilitas tersebut menarik banyak investor lokal dan asing karena menawarkan kesempatan imbal hasil yang tinggi. Jumlah perusahaan yang terdaftar di BEI meningkat menjadi 483 di tahun 2013 dari 238 di tahun 1995. Total volume perdagangan mencapai 1.342 miliar saham dengan total kapitalisasi pasar sebesar Rp. 4.219 triliun di tahun 2013 (BEI, 2013). Indeks Harga Saham Gabungan (IHSG) merupakan indikator utama yang digunakan di BEI untuk mengukur kinerja pasar saham secara keseluruhan. IHSG merupakan indeks kapitalisasi pasar tertimbang dan mewakili setidaknya 70% dari total kapitalisasi pasar dan jumlah saham yang diperdagangkan. Peramalan yang akurat mengenai pergerakan indeks dapat digunakan sebagai *leading indicator* kondisi pasar saham dan sebagai dasar untuk mengembangkan strategi perdagangan pasar saham yang efektif.

Dasar teori pasar saham terutama yang terkait dengan peramalan pasar saham adalah hipotesis pasar-efisien yang dikemukakan oleh Eugene Fama pada tahun 1965. Fama (1965) menyatakan bahwa pasar saham sangat efisien dalam memproses informasi dan beradaptasi begitu cepat terhadap informasi baru sehingga harga setiap saat sudah mencerminkan semua informasi yang tersedia. Pergerakan harga di pasar saham sangat dipengaruhi oleh informasi baru, dan informasi baru pada dasarnya adalah acak. Oleh karena itu masing-masing pengamatan dalam deret waktu pergerakan harga seharusnya acak dan tidak mempunyai korelasi satu sama lain atau independen. Pasar dimana masing-masing pergerakan adalah independen adalah pasar dengan proses *random walk*. Menurut teori *random walk*, peramalan terbaik untuk harga saham merupakan fungsi dari harga saat ini ditambah dengan *random error*. Sebagai akibatnya, metode analisis yang menggunakan data historis perdagangan saham tidak berguna untuk menghasilkan peramalan.

Terdapat berbagai pendekatan yang digunakan untuk melakukan peramalan pasar saham. Analisis teknikal adalah metode analisis pasar saham untuk peramalan pergerakan harga dengan menggunakan data historis perdagangan saham terutama data harga dan volume (Kirckpatrick & Dahlquist, 2011). Metode ini menekankan pada penggunaan grafik dan indikator pasar saham untuk mendeteksi pergerakan harga saham. Analisis teknikal menolak hipotesis pasar efisien dan mengaggaskan bahwa pergerakan harga membentuk suatu tren dan pola yang berulang yang dapat diramalkan. Dasar pemikiran analisis teknikal adalah bahwa semua faktor yang dapat mempengaruhi harga saham, baik faktor ekonomi, politik, ataupun psikologi investor, akan tercermin dalam harga dan volume.

*Autoregressive Integrated Moving Average* (ARIMA) merupakan model deret waktu linear yang berguna baik untuk memahami proses deret waktu maupun untuk menghasilkan peramalan. Model ini merupakan model deret waktu univariat yang memproyeksikan atau mengekstrapolasi nilai-nilai historis dari variabel yang diramalkan dengan mengidentifikasi pola-pola masa lalu yang terdapat pada data. ARIMA terdiri dari dua komponen yaitu model autoregresif dan model *moving average*. Autoregresi memodelkan autokorelasi variabel deret waktu yang tergantung secara linear pada nilai-nilai variabel sebelumnya. Model *moving average* memodelkan autokorelasi dari kesalahan/*error* sebelumnya yang terdapat pada data deret waktu (Hanke & Wichern, 2009). ARIMA merupakan generalisasi dari model ARMA yang dapat diaplikasikan pada data deret waktu nonstasioner melalui diferensiasi deret waktu.

Beberapa penelitian telah dilakukan untuk melakukan peramalan harga saham menggunakan ARIMA. Sudirman & Damayanti (2014) melakukan estimasi model peramalan pada indeks harga saham gabungan untuk lima negara ASEAN termasuk Indonesia. Wuryandani (2011) melakukan penelitian untuk mengetahui perilaku pergerakan harga di BEI dengan melakukan beberapa estimasi model peramalan IHSG termasuk ARIMA. Hasil dari penelitian tersebut menunjukkan bahwa ARIMA adalah model yang berguna untuk peramalan di pasar saham.

*Neural Network Autoregression* (NAR) adalah model peramalan deret waktu yang menggunakan variabel lag sebagai *input* kedalam sistem jaringan syaraf tiruan (Hyndman & Athanasopoulos, 2013). Jaringan syaraf tiruan (JST) adalah model yang sangat baik untuk memecahkan permasalahan nonlinear dan telah diterapkan dalam berbagai macam aplikasi dari segala bidang termasuk untuk prediksi pasar saham (Herdinata, 2008; Frenandez-Rodriguez, 2000; Khashei & Bijari, 2010). JST adalah model nonparametrik yang tidak bergantung pada asumsi seperti stasioneritas, normalitas, dan heteroskedastisitas, sehingga dapat digunakan untuk mengidentifikasi hubungan nonlinear yang kompleks antara variabel prediktor dan variabel respon dengan akurasi yang tinggi.

Untuk mengetahui apakah pergerakan harga saham di BEI mengikuti proses *random walk* dan sesuai dengan hipotesis pasar-efisien bentuk lemah atau terdapat proses lain yang dapat dimodelkan untuk peramalan, penelitian ini bertujuan menghasilkan dan membandingkan tiga model peramalan yaitu *Random Walk with Drift* (RWD), ARIMA, dan NAR. Masing-masing tahap dalam pemodelan Box-Jenkins dilakukan untuk menghasilkan model ARIMA yang sesuai. Jumlah lag autoregresi yang dihasilkan kemudian digunakan sebagai *input* ke dalam sistem jaringan syaraf tiruan *feed-forward/backpropagation* dengan satu *hidden layer* untuk menghasilkan peramalan NAR. Akurasi peramalan RWD, ARIMA, dan NAR kemudian diukur dan dibandingkan menggunakan *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE).

## **1.2 Perumusan Masalah**

Berdasarkan latar belakang yang telah disampaikan maka perumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Apakah pergerakan harga saham di Bursa Efek Indonesia mengikuti proses *random walk* dan sesuai dengan hipotesis pasar-efisien atau terdapat proses lain yang dapat dimodelkan untuk peramalan?
2. Bagaimana menghasilkan model peramalan untuk IHSG?
3. Bagaimana akurasi model peramalan yang dihasilkan?



### 1.3 Tujuan

Berdasarkan perumusan masalah yang telah disampaikan maka tujuan yang ingin dicapai dari penelitian ini adalah sebagai berikut:

1. Mengetahui apakah pergerakan harga saham di Bursa Efek Indonesia mengikuti proses *random walk* dan sesuai dengan hipotesis pasar-efisien.
2. Menghasilkan model peramalan RWD, ARIMA, dan NAR untuk IHSG.
3. Menghasilkan dan membandingkan akurasi model peramalan.

### 1.4 Kontribusi

Penelitian ini diharapkan dapat memberikan kontribusi dalam bidang peramalan indeks harga saham dan pengujian hipotesis pasar-efisien bentuk lemah dengan membuktikan apakah pergerakan harga saham di Bursa Efek Indonesia mengikuti proses *random walk* atau terdapat proses lain khususnya ARIMA dan NAR yang dapat dimodelkan untuk peramalan. Perbedaan penelitian ini dengan penelitian Sudirman & Damayanti (2014) dan Wuryandani (2010) adalah, identifikasi dan estimasi ARIMA dalam penelitian ini menggunakan algortima pemodelan untuk mengidentifikasi orde dari proses AR dan MA, dan melakukan estimasi beberapa model awal secara iteratif menggunakan *Maximum Likelihood Estimation* (MLE) sampai menemukan *Akaike Information Criterion* (AIC) terkecil secara otomatis (Hyndman & Khandakar, 2008). Wuryandani lebih lanjut melakukan analisis heteroskedastisitas dan memodelkannya dengan *generalized Autoregressive Conditional Heteroskedasticity* (GARCH). Penelitian ini memanfaatkan jumlah lag autoregresi yang dihasilkan ARIMA sebagai *input* ke model non-parametrik JST yang tidak mengasumsikan heteroskedastisitas.

### 1.5 Manfaat

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Peramalan yang akurat dapat digunakan sebagai *leading indicator* kondisi pasar saham.
2. Model peramalan yang dihasilkan dapat digunakan sebagai dasar dalam mengembangkan strategi perdagangan saham.

## 1.6 Batasan Masalah

Penelitian mengenai peramalan pasar saham mempunyai ruang lingkup yang luas. Terdapat berbagai jenis efek yang dapat dianalisa dan juga terdapat berbagai macam model peramalan dan berbagai faktor yang harus dipertimbangkan. Oleh karena itu, agar dapat mencapai tujuan penelitian maka diberlakukan batasan masalah sebagai berikut:

1. Data yang dianalisis adalah deret waktu univariat harga penutupan harian indeks harga saham gabungan (IHSG) periode Januari 2010-Desember 2014 dengan waktu dasar 10 Agustus 1982. Data IHSG yang dianalisis dalam hal ini tidak mempertimbangkan saham-saham sektoral ataupun individual yang merupakan komponen dari IHSG.
2. Sistem JST yang digunakan adalah *multilayer feed-forward* dengan satu *hidden layer* menggunakan algoritma *backpropagation*.
3. Pengolahan data menggunakan metode *hold-out* dimana dataset *training* digunakan untuk estimasi dan dataset *testing* digunakan untuk prediksi dan evaluasi akurasi.

## 1.7 Sistematika Penulisan

Sistematika penulisan yang digunakan dalam penelitian ini adalah sebagai berikut:

1. BAB 1: Pendahuluan  
Bab ini menyampaikan latar belakang, perumusan masalah, tujuan, kontribusi, manfaat, batasan masalah dan sistematika penulisan.
2. BAB 2: Tinjauan Pustaka dan Dasar Teori  
Bab ini menyampaikan tinjauan pustaka dan dasar teori terkait yang diperoleh dari berbagai referensi.
3. BAB 3: Metode Penelitian  
Bab ini menguraikan metode yang digunakan dalam pengolahan dan pemodelan data.
4. BAB 4: Hasil dan Pembahasan  
Bab ini memberikan hasil dan pembahasan dari penelitian yang dilakukan.

## 5. BAB 5: Kesimpulan dan Saran

Bab ini menarik kesimpulan dari semua hasil temuan dalam penelitian dan memberikan saran untuk perbaikan.

## **BAB 2**

### **TINJAUAN PUSTAKA DAN DASAR TEORI**

#### **2.1 Hipotesis Pasar-Efisien**

Hipotesis pasar-efisien menyatakan bahwa pasar saham sangat efisien dalam memproses informasi dan beradaptasi begitu cepat terhadap informasi baru sehingga harga setiap saat sudah mencerminkan semua informasi yang tersedia. Kekuatan pendorong efisiensi pasar adalah kepentingan pribadi untuk mencari sekuritas yang dinilai terlalu tinggi atau terlalu rendah. Semakin banyak pelaku pasar dan semakin cepat informasi dirilis, semakin pasar menjadi efisien. Informasi baru dapat mengakibatkan perubahan nilai intrinsik suatu sekuritas, namun pergerakan harga berikutnya tidak akan mempunyai pola yang dapat diprediksi (Van Horne & Wachowicz, 2008).

Menurut Fama (1965), pergerakan harga di pasar saham yang efisien dipengaruhi oleh informasi baru, dan informasi baru pada dasarnya adalah acak. Oleh karena itu, deretan perubahan harga seharusnya acak dan tidak mempunyai korelasi satu sama lain atau independen. Pasar dimana deretan perubahan harga adalah independen secara definisi adalah pasar dengan proses *random walk*. *Random walk* adalah teori pasar saham yang menyatakan bahwa pergerakan harga adalah acak dan tidak dapat diprediksi. Implikasi dari teori ini adalah bahwa peramalan menggunakan data historis perdagangan saham, maupun data lain yang tersedia, baik secara publik atau internal (*inside information*), tidak dapat digunakan untuk peramalan.

Menurut Bodie et al (2014) teori *random walk* sekilas menyiratkan bahwa pergerakan harga di pasar saham didominasi oleh psikologi pasar yang tidak menentu dan bahkan tampak irasional. Namun deretan perubahan yang acak tersebut merupakan akibat dari pelaku pasar rasional yang merespon dengan seketika terhadap informasi baru. Peramalan mengenai kenaikan harga suatu saham di masa depan yang dirilis ke publik, akan menyebabkan harga naik dengan seketika, karena pelaku pasar akan segera membeli saham tersebut sebelum harga naik.

Terdapat tiga macam bentuk efisiensi pasar berdasarkan informasi yang diproses. Masing-masing bentuk menunjukkan sejauh mana dan seberapa cepat informasi tersebut mempengaruhi pasar (Bodie et al, 2014):

1. Bentuk lemah (*weak form*) menyatakan bahwa harga saham sudah mencerminkan semua informasi terkait data perdagangan saham, yaitu data harga dan volume. Karena harga sudah mencerminkan semua informasi, efisiensi pasar bentuk lemah berasumsi bahwa data historis pada masing-masing pengamatan tidak mempunyai korelasi atau independen. Sebagai akibatnya, analisis yang menggunakan data harga dan volume tidak dapat digunakan untuk peramalan.
2. Bentuk semi-kuat (*semi-strong form*) menyatakan bahwa harga saham sudah mencerminkan semua informasi publik terkait prospek perusahaan termasuk data non-pasar. Sebagai akibatnya, metode analisis yang menggunakan berbagai informasi yang tersedia secara publik tidak dapat digunakan untuk peramalan. Baik analisis fundamental maupun analisis teknikal, tidak dapat digunakan untuk mendapatkan imbal hasil lebih.
3. Bentuk kuat (*Strong form*) menyatakan bahwa harga saham sudah mencerminkan semua informasi baik informasi yang tersedia bagi publik maupun informasi internal perusahaan. Hal ini berarti bahwa tidak ada seseorangpun yang mempunyai akses monopoli terkait informasi pasar saham. Bentuk kuat berasumsi bahwa semua informasi adalah bebas-biaya dan tersedia bagi semua orang. Sebagai akibatnya, praktik perdagangan orang dalam (*insider trading*), meskipun merupakan bentuk praktik ilegal di bursa saham, tidak dapat dilakukan untuk memperoleh imbal hasil lebih sesuai risiko. Bentuk kuat efisiensi pasar dapat dikatakan tidak sesuai dengan kenyataan, karena orang dalam perusahaan tentunya akan dapat memperoleh keuntungan lebih melalui penyalahgunaan informasi yang belum dirilis ke publik.

## 2.2 Penelitian Sebelumnya

Sudirman & Damayanti (2014) melakukan estimasi model peramalan pada indeks harga saham gabungan untuk lima negara ASEAN yaitu Indonesia, Malaysia, Singapura, Filipina, dan Thailand menggunakan pemodelan Box-Jenkins ARIMA pada data periode tahun 2000-2012. Analisis Fungsi Autokorelasi (ACF) dan Autokorelasi Parsial (PAFC) dilakukan untuk mengidentifikasi proses AR dan MA. Pemilihan model terbaik dilakukan dengan mengamati signifikansi koefisien masing-masing model dan memilih model dengan *Sum of Square Error* (SSE) terkecil. Diagnostik residual dan uji normalitas dilakukan dengan menggunakan uji Ljung-Box dan Kolmogorov-Smirnov. Berdasarkan analisis diputuskan bahwa model estimasi terbaik pada kelima bursa efek adalah ARIMA (2,1,1) untuk Indonesia, ARIMA (6,1,2) untuk Malaysia, ARIMA (5,1,5) untuk Singapura, ARIMA (2,1,0) untuk Filipina, dan ARIMA (4,1,0) untuk Thailand.

Wuryandani (2010) melakukan penelitian untuk mengetahui perilaku pergerakan harga di BEI dengan melakukan estimasi model peramalan IHSG pada data periode tahun 2006-2009 dan menghasilkan ARIMA(1,1,1), ARIMA(1,1,0), dan ARIMA(0,1,1). Pemilihan model terbaik dilakukan menggunakan *adjusted R squared* dimana ARIMA(1,1,0) menghasilkan nilai tertinggi. Wuryandani selanjutnya menemukan bahwa masih terdapat heteroskedastisitas pada residual peramalan. Heteroskedastisitas kemudian dimodelkan dengan *Generalized Autoregressive Conditional Heteroskedasticity* dan menghasilkan GARCH(1,1).

Herdinata (2008) dalam ulasannya menyatakan bahwa aplikasi Jaringan Syaraf Tiruan (JST) untuk peramalan keuangan merupakan penelitian yang menarik perhatian para peneliti. Penelitian-penelitian yang dilakukan seringkali bermaksud untuk menguji hipotesis pasar-efisien dan menguji efektifitas model JST. Untuk menguji efektifitas model peramalan biasanya digunakan ukuran tingkat kesalahan/*error* yang menunjukkan akurasi peramalan. Namun untuk dapat digunakan sebagai strategi perdagangan dalam kondisi pasar keuangan nyata, efektifitas model peramalan juga harus diuji kinerjanya dari segi profitabilitas.

Fernando-Rodriguez (2000) menguji profitabilitas strategi perdagangan berdasarkan sinyal jual dan beli yang dihasilkan model peramalan JST pada data

imbal hasil harian (*daily return*) Indeks General Bursa Efek Madrid periode Januari 1996 - Oktober 1997. 9 variabel *lag* digunakan sebagai input ke dalam sistem JST *feed-forward backpropagation* yang terdiri dari satu *hidden layer* dengan 4 unit, dan satu *ouput unit*. Bobot masin-masing unit diperoleh secara iteratif menggunakan metode *gradient descent* untuk menghasilkan *sum of squared error* terkecil. Sistem di uji pada tiga subperiode dengan kondisi pasar *bullish* (tren naik), *stable* (naik turun), dan *bearish* (tren turun). Tingkat imbal hasil menggunakan ukuran *total return*, *random walk/buy-and-hold return*, *ideal profit*, dan *sharpe ratio* menunjukan bahwa strategi perdagangan berdasarkan sistem JST menghasilkan imbal hasil lebih tinggi dibandingkan strategi beli-tahan (*buy-and-hold*).

## 2.3 Indeks Harga Saham

Indeks harga saham adalah indikator atau cerminan pergerakan harga dari sekumpulan saham. Indeks harga saham merupakan salah satu pedoman bagi investor untuk melakukan investasi di pasar modal. Pada umumnya terdapat dua metode perhitungan indeks harga saham yaitu (Koop, 2006):

### 1. Indeks Harga Tertimbang

Indeks harga tertimbang menghitung angka indeks dengan cara membagi rata-rata harga saham yang terdapat di dalam komposisi indeks pada waktu  $t$ , dengan rata-rata harga pada waktu dasar (*base value*). Metode ini menggunakan harga sebagai rata-rata tertimbang untuk perhitungan indeks sebagai berikut:

$$\text{Indeks Harga Tertimbang} = \frac{1}{n} \sum_{i=1}^n \frac{P_{i,t}}{P_{i,\text{tdasar}}} \times 100$$

(2.1)

dimana,

$P_{it}$  = harga saham  $i$  pada waktu  $t$

$n$  = jumlah saham dalam komposisi

### 2. Indeks Kapitalisasi-Pasar Tertimbang

Indeks kapitalisasi-pasar tertimbang menghitung rata-rata tertimbang berdasarkan kapitalisasi pasar. Angka indeks diperoleh dengan membagi nilai kapitalisasi pasar saham-saham yang terdapat di dalam komposisi indeks pada waktu  $t$ , dengan nilai kapitalisasi pasar pada waktu dasar, dimana kapitalisasi pasar adalah harga pasar dikali jumlah lembar saham. Perhitungan indeks kapitalisasi-pasar tertimbang:

$$\text{Indeks Kapitalisasi-Pasar Tertimbang} = \frac{\sum_{i=1}^n P_{i,t} Q_{i,t}}{\sum_{i=1}^n P_{i,\text{dasar}} Q_{i,t}} \times 100 \quad (2.2)$$

dimana,

$P_{it}$  = harga saham  $i$  pada waktu  $t$

$Q_{it}$  = jumlah lembar saham  $i$  pada waktu  $t$

$n$  = jumlah saham dalam komposisi

## 2.4 Analisis Teknikal

Analisis teknikal adalah metode analisis pasar saham untuk peramalan pergerakan harga dengan menggunakan data historis perdagangan saham terutama data harga dan volume. Metode ini menekankan pada penggunaan grafik dan berbagai indikator pasar saham untuk mendeteksi pergerakan harga saham. Analisis teknikal juga menggunakan beberapa metode pemulusan eksponensial untuk mendeteksi tren dan pola berulang. Dasar pemikiran analisis teknikal adalah bahwa semua faktor yang dapat mempengaruhi harga saham, baik faktor ekonomi, politik, ataupun psikologi investor, akan tercermin dalam harga dan volume.

Analisis teknikal dapat digunakan untuk analisis saham, indeks saham, komoditas, kontrak berjangka, valutas asing, atau instrumen lain yang diperdagangkan di bursa dimana harga dipengaruhi oleh kekuatan penawaran dan permintaan. Indikator harga di pasar saham yang dianalisis merupakan kombinasi dari harga pembukaan (*open*), harga tertinggi (*high*), harga terendah (*low*), dan harga penutupan (*close*) selama kurun waktu tertentu. Beberapa indikator harga yang sering digunakan adalah *OHLC chart*, *Candlestick*, dan *Heiken Ashi*.



Menurut Kirkpatrick & Dahlquist (2011) tren adalah hal yang paling penting dalam analisis teknikal. Tujuan utama analisis teknikal adalah mengidentifikasi tren secara keseluruhan untuk mengetahui apakah tren mempunyai arah yang naik atau turun. Hal ini dilakukan menggunakan garis tren, regresi linear, rata-rata bergerak, pemulusan eksponensial dan metode lainnya. Selama harga masih berada di atas garis tren yang naik maka tren diasumsikan akan terus menaik. Ketika harga memotong garis tren maka hal ini digunakan sebagai sinyal bahwa tren akan berubah arah.

Momentum mengukur kekuatan pergerakan tren yang terjadi. Menurut Appel (2005) momentum pasar saham dapat diukur menggunakan *Moving Average Convergence/Divergence* (MACD). MACD adalah indikator untuk mengukur apakah tren mempunyai momentum yang kuat sehingga akan berlanjut. Jika nilai MACD berada di atas *Exponential Moving Average* (EMA), hal ini merupakan indikasi bahwa tren mempunyai momentum yang kuat. Jika sebaliknya, maka hal ini merupakan indikasi momentum yang melemah.

## **2.5 Analisis Deret Waktu**

Tujuan utama pemodelan deret waktu adalah mengumpulkan dan mempelajari data deret waktu untuk mengembangkan model yang sesuai dengan data. Model ini kemudian digunakan untuk menghasilkan nilai-nilai masa depan, yaitu untuk menghasilkan peramalan. Peramalan deret waktu dapat disebut sebagai tindakan memprediksi masa depan dengan memahami masa lalu (Adhikari & Agrawal, 2013).

### **2.5.1 Definisi Deret Waktu**

Deret waktu adalah data nilai-nilai pengamatan yang dikumpulkan dari suatu sistem atau proses dan diukur secara kronologis selama kurun waktu tertentu dengan interval yang sama (Bisgaard & Kulahci, 2011). Deret waktu yang berisi pengamatan dari satu variabel disebut sebagai deret waktu univariat. Deret waktu univariat hanya menggunakan informasi yang terdapat pada variabel yang akan diramalkan dan tidak berupaya untuk menjelaskan variabel eksternal yang dapat mempengaruhi variabel peramalan (Adhikari & Agrawal, 2013).

### 2.5.2 Stasioneritas Deret Waktu

Stasioneritas merupakan hal yang esensial dalam peramalan deret waktu. Deret waktu stasioner adalah deret waktu dimana mean, varians, dan kovarians adalah konstan dari waktu ke waktu. Suatu deret waktu bersifat stasioner apabila (Defusco et al, 2007):

1. Nilai ekspektasi/*mean* deret waktu adalah konstan dan terbatas dalam semua periode:

$$E(y_t) = \mu \text{ dan } |\mu| < \infty, t = 1, 2, \dots, T \quad (2.3)$$

2. Varians dan Kovarians deret waktu dengan deret waktu itu sendiri adalah konstan dan terbatas dalam semua periode:

$$\text{Cov}(y_t, y_{t-s}) = \lambda, |\lambda| < \infty, t = 1, 2, \dots, T; s = 0, \pm 1, \pm 2, \dots, \pm T \quad (2.4)$$

### 2.5.3 Backshift Operator

Operator *backshift*  $B$ , jika dioperasikan pada variabel deret waktu, akan menggeser deret waktu sebanyak satu unit. Operator ini sangat berguna untuk menyederhanakan persamaan model deret waktu yang melibatkan variabel lag. Operator *backshift* diberikan sebagai (Bisgaard & Kulahci, 2011):

$$By_t = y_{t-1} \quad (2.5)$$

### 2.5.4 Diferensiasi

Sebagian besar deret waktu pasar saham adalah nonstasioner. Diferensiasi merubah deret waktu nonstasioner menjadi stasioner dengan menghasilkan deret waktu baru yang merupakan perbedaan antara nilai variabel dalam satu periode dengan periode sebelumnya. Diferensiasi deret waktu tingkat pertama diberikan sebagai (Hyndman & Athanasopoulos, 2013):

$$y'_t = y_t - y_{t-1} = y_t - By_t = (1-B)y_t \quad (2.6)$$

Secara umum, diferensiasi dengan tingkat  $d$  diberikan dengan:

$$(1-B)^d y_t \quad (2.7)$$

dimana,  $B$  adalah operator *backshift*:  $By_t = y_{t-1}$

### 2.5.5 Transformasi Box-Cox

Tujuan dari transformasi adalah menyederhanakan pola dalam data historis dengan menghilangkan variasi atau dengan membuat pola yang lebih konsisten pada seluruh data. Pola yang lebih sederhana akan menghasilkan peramalan yang lebih akurat. Jika deret waktu diidentifikasi mempunyai varians yang tidak konstan, salah satu penyesuaian yang dapat dilakukan adalah melalui transformasi Box-Cox sebagai berikut (Hyndman & Athanasopoulos, 2013):

$$w_t = \begin{cases} \log(y_t) & , \lambda=0; \\ (y_t^\lambda - 1) / \lambda & , \lambda \neq 0 \end{cases} \quad (2.8)$$

dimana,  $\lambda$  = parameter transformasi.

### 2.5.6 Uji *Augmented* Dickey-Fuller (ADF)

Uji akar unit Dickey-Fuller adalah uji hipotesis yang digunakan untuk menentukan apakah deret waktu mempunyai akar unit. Untuk uji ini, digunakan model autoregresi orde 1, AR(1), dan menguji signifikansi koefisien  $\delta$  sebagai berikut (Defusco, 2007):

$$\begin{aligned} y_t &= \phi_1 y_{t-1} + \varepsilon_t \\ y_t - y_{t-1} &= \phi_1 y_{t-1} - y_{t-1} + \varepsilon_t \\ \Delta y_t &= (\phi - 1)y_{t-1} + \varepsilon_t = \delta y_{t-1} + \varepsilon_t \end{aligned} \quad (2.9)$$

Selain itu dapat juga ditambahkan koefisien drift dan beberapa lag. Uji *Augmented* Dickey-Fuller menggunakan model autoregresi orde p, AR(p), dan menguji signifikansi koefisien  $\delta$  sebagai berikut (Katchova, 2013):

$$\Delta y_t = c + \delta y_{t-1} + \sum_{j=1}^{p-1} \phi_j \Delta y_{t-j} + \varepsilon_t \quad (2.10)$$

Jika deret waktu mempunyai akar unit, maka  $\phi_1 = 1$  dan  $\delta = 0$ , sehingga nonstasioner. Uji dilakukan menggunakan t-test dan nilai kritis pada tabel Dickey-Fuller.

### 2.5.7 Fungsi Autokorelasi dan Autokorelasi Parsial

Fungsi autokorelasi (ACF) mengukur bagaimana urutan pengamatan dalam deret waktu berkorelasi satu sama lain. Fungsi autokorelasi antara  $y_t$  dengan  $y_{t-k}$  diberikan dengan (Katchova, 2013):

$$ACF(k) = \rho_k = \frac{Cov(y_t, y_{t-k})}{Var(y_t)} \quad (2.11)$$

Autokorelasi parsial adalah autokorelasi antara  $y_t$  dan  $y_{t-k}$  tanpa memperhitungkan korelasi yang terdapat pada lag 1,2,...,t-k+1. Fungsi autokorelasi parsial diberikan dengan:

$$PACF(k) = \rho_k^* = Corr[y_t - E^*(y_t | y_{t-1}, \dots, y_{t-k+1}, y_{t-k})] \quad (2.12)$$

Batas kritis untuk ACF dan PACF adalah  $\pm 1.96 / \sqrt{T}$  dimana,  $T$  = jumlah data deret waktu.

### 2.5.8 Autoregressive Moving Average (ARMA)

Ketika data mempunyai autokorelasi, sebagian besar metode peramalan yang didasarkan pada asumsi pengamatan independen menjadi tidak absah. Deret waktu stasioner dengan autokorelasi dapat dimodelkan menggunakan *Autoregressive Moving Average*. ARMA terdiri dari dua komponen yaitu *autoregressive* dan *moving average* (Bisgaard & Kulahci, 2011).

*Autoregressive (AR)* adalah model deret waktu yang melakukan regresi terhadap nilai pengamatan masa lalu yaitu variabel lag. Autoregresi dengan lag  $p$ ,  $AR(p)$ , diberikan dengan (Hyndman & Athanasopoulos, 2013):

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (2.13)$$

dimana,

$c$  = konstanta

$\phi$  = parameter model

$y_{t-p}$  = variabel lag  $p$

$\varepsilon_t$  = *error* periode  $t$

*Moving Average* (MA) adalah model deret waktu yang melakukan regresi terhadap kesalahan masa lalu (*lagged error*) untuk menghasilkan peramalan. *Moving Average* lag  $q$ ,  $MA(q)$ , diberikan dengan (Hyndman & Athanasopoulos, 2013):

$$y_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.14)$$

dimana,

$\theta$  = parameter model

$\varepsilon_{t-q}$  = *error* pada periode  $t$  lag  $q$

*Autoregressive* (AR) dan *Moving Average* (MA) dapat secara efektif dikombinasikan untuk membentuk model deret waktu yang dikenal sebagai model ARMA. ARMA( $p, q$ ) diberikan dengan:

$$y_t = c + \phi_1 y'_{t-1} + \dots + \phi_p y'_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (2.15)$$

### 2.5.9 Identifikasi ARMA

Identifikasi orde  $p$  dan  $q$  yang sesuai dapat dilakukan secara visual dengan menggunakan korelogram. Korelogram merupakan plot fungsi autokorelasi (ACF) dan fungsi autokorelasi parsial (PACF). Pola pada sampel ACF dan PACF kemudian dibandingkan dengan pola dari proses ARMA teoritis. Dalam prakteknya sampel ACF dan PACF adalah variabel acak dan tidak akan memberikan gambaran yang sama persis seperti fungsi teoritis. Tabel 2.1 berikut memberikan karakteristik ACF dan PACF ARMA.

Tabel 2.1 Karakteristik ACF dan PACF proses ARMA.

Proses	ACF	PACF
AR( $p$ )	<i>Tails off</i> secara bertahap	<i>Cutt off</i> setelah lag $p$
MA( $q$ )	<i>Cutt off</i> setelah lag $q$	<i>Tails off</i> secara bertahap
ARMA( $p, q$ )	<i>Tails off</i> secara bertahap	<i>Tails off</i> secara bertahap

### 2.5.10 Deret Waktu Nonstasioner

Model ARMA mengasumsikan deret waktu stasioner. Namun dalam prakteknya banyak deret waktu menunjukkan perilaku nonstasioner. Tren dan/atau pola musiman menunjukkan bahwa deret waktu nonstasioner. Oleh karena itu model ARMA tidak dapat digunakan untuk deret nonstasioner yang sering ditemui di dunia nyata (Adhikari & Agrawal, 2013).

### 2.5.11 Random Walk

Model *random walk* adalah model deret waktu nonstasioner dimana nilai variabel dalam periode  $t$  adalah sama dengan nilai pengamatan pada periode terakhir,  $t-1$ , ditambah dengan gangguan/error acak yang tak terduga. Model *random walk* diberikan sebagai (Defusco et al, 2007):

$$\begin{aligned} y_t &= y_{t-1} + \varepsilon_t, \\ E(\varepsilon_t) &= 0, E(\varepsilon_t^2) = \sigma^2, E(\varepsilon_t \varepsilon_s) = 0 \end{aligned} \quad (2.16)$$

Model tersebut menunjukkan bahwa deret waktu  $y_t$  dalam setiap periode merupakan fungsi dari nilai pada periode sebelumnya ditambah  $\varepsilon_t$ , yang mempunyai varians konstan dan tidak berkorelasi dengan periode sebelumnya. Model *random walk* ekuivalen dengan model AR(1) dengan  $\phi_1 = 1$  dan  $c = 0$ . Oleh karena ekspektasi dari  $E(\varepsilon_t) = 0$ , maka peramalan terbaik untuk  $y_t$  adalah  $y_{t-1}$ .

### 2.5.12 Random Walk with Drift

Model *Random walk with drift* adalah model *random walk* dengan  $E(\varepsilon_t) \neq 0$ . Model ini diberikan dengan (Hyndman & Athanasopoulos, 2013):

$$\begin{aligned} y_t - y_{t-1} &= c + \varepsilon_t \text{ atau} \\ y_t &= c + y_{t-1} + \varepsilon_t \end{aligned} \quad (2.17)$$

Konstanta  $c$  merupakan rata-rata perubahan deret waktu dari semua periode. Jika  $c$  adalah positif maka  $y_t$  akan cenderung mempunyai *drift* dengan arah naik dan sebaliknya. Model *drift* ekuivalen dengan model AR(1) dengan  $\phi_1 = 1$  dan  $c \neq 0$ .

### 2.5.13 Autoregressive Integrated Moving Average (ARIMA)

ARIMA merupakan model deret waktu yang memanfaatkan diferensiasi pada model ARMA sehingga dapat digunakan untuk pemodelan deret waktu nonstasioner. ARIMA menggunakan diferensiasi deret waktu dengan tingkat  $d$  untuk menghasilkan deret waktu stasioner. Model ARIMA( $p,d,q$ ) diberikan sebagai (Hyndman & Athanasopoulos, 2013):

$$y'_t = c + \phi_1 y'_{t-1} + \dots + \phi_p y'_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (2.18)$$

Ketiga komponen ARIMA tampak lebih jelas apabila ditulis menggunakan operator *backshift*,  $By_t = y_{t-1}$ , sebagai berikut:

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - B)^d y_t = c + (1 + \theta_1 B + \dots + \theta_q B^q) \varepsilon_t \quad (2.19)$$

dimana,

- $p$  = orde autoregresif
- $d$  = tingkat diferensiasi
- $q$  = orde *moving average*


ARIMA dapat digunakan untuk pemodelan berbagai proses deret waktu baik yang stasioner maupun nonstasioner karena model ARIMA menggabungkan komponen AR, MA dan diferensiasi. Tabel 2.2 memberikan ekuivalensi beberapa proses deret waktu dengan model ARIMA( $p,d,q$ ).

Tabel 2.2 Beberapa proses deret waktu dalam bentuk ARIMA.

Proses	ARIMA( $p,d,q$ )
<i>White Noise</i>	ARIMA(0,0,0)
<i>Random Walk</i>	ARIMA(0,1,0)
<i>Random Walk with Drift</i>	ARIMA(0,1,0) dengan konstanta
<i>Autoregression</i>	ARIMA( $p,0,0$ )
<i>Moving Average</i>	ARIMA(0,0, $q$ )

## 2.6 Pemodelan Box-Jenkins

Pemodelan Box-Jenkins merupakan metode yang dikembangkan oleh G.E.P. Box dan G.M. Jenkins untuk menghasilkan model ARIMA yang optimal menggunakan tiga tahap secara iteratif seperti pada Gambar 2.1 berikut.



Gambar 2.1 Diagram Alir Pemodelan Box-Jenkins (Hanke & Wichern, 2009).

Tahap pertama adalah melakukan identifikasi menggunakan plot deret waktu untuk melihat apakah terdapat tren dan atau pola musiman yang dapat dimodelkan. Plot deret waktu membantu untuk menentukan model awal yang sesuai dengan pola yang terdapat pada data deret waktu. Stasioneritas deret waktu diidentifikasi menggunakan plot fungsi autokorelasi (ACF) dan fungsi autokorelasi parsial (PACF) dan dengan uji *Augmented* Dickey-Fuller (ADF). Transformasi dan diferensiasi yang sesuai selanjutnya dilakukan untuk menghasilkan deret waktu yang stasioner. Jumlah lag ACF dan PACF pada deret waktu yang sudah stasioner kemudian digunakan untuk menentukan orde dari model ARMA. Estimasi parameter kemudian dilakukan pada beberapa model ARMA yang akan dicoba. Diagnostik dilakukan untuk memeriksa signifikansi parameter dan memeriksa apakah residual peramalan mempunyai rata-rata yang tidak berbeda signifikan dari nol dan tidak berkorelasi. Jika asumsi tersebut telah terpenuhi maka model dapat digunakan untuk peramalan. Jika tidak maka dapat kembali ke tahap identifikasi untuk mencoba mencari model yang lebih baik.




## 2.7 Jaringan Syaraf Tiruan

Jaringan syaraf tiruan (JST) merupakan metode komputasi yang memodelkan hubungan antara variabel input dan output yang terinspirasi oleh bagaimana sel-sel otak memproses stimuli yang diterima dari indera. Menurut Lantz (2013) sinyal masukan dari indera diterima oleh sel dendrit melalui suatu proses biokimia yang memungkinkan impuls ditimbang berdasarkan tingkat kepentingan atau frekuensi. Pada saat sel neuron mulai mengakumulasi sinyal yang masuk, suatu ambang batas tertentu tercapai dimana sel menjadi aktif dan mentransmisikan sinyal keluaran melalui suatu proses elektrokimia melalui jalur bernama akson. Pada terminal akson sinyal elektrik ini kemudian diproses untuk ditransmisikan lagi melalui celah sinapsis yang terhubung ke sel-sel neuron sekitarnya.


### 2.7.1 Multilayer Feed-forward Neural Network

*Multilayer Feed-forward Neural Network* adalah salah satu model Jaringan Syaraf Tiruan (JST) yang terdiri dari lapisan masukan (*input layer*), satu atau lebih lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*). Setiap lapisan terdiri dari unit-unit (*neuron* tiruan) yang saling terhubung dan masing-masing unit menerima *input* dari lapisan sebelumnya dan mengirimkan *output* ke lapisan berikutnya. JST memodelkan hubungan antara variabel *input*  $x_1, x_2, \dots, x_n$  dan variabel *output*  $o_1, o_2, \dots, o_k$  seperti ditunjukkan pada Gambar 2.2.



Gambar 2.2 *Multilayer Feed-forward Neural Network* (Han et al, 2010).

Masing-masing *input*  $x_1, x_2, x_3, \dots, x_n$  dari lapisan sebelumnya ditimbang berdasarkan bobot  $w_1, w_2, w_3, \dots, w_n$  dan diakumulasi. Fungsi aktivasi kemudian memproses masukan total dan bila mencapai ambang batas maka *output* dikirimkan ke unit lain pada lapisan berikutnya. JST menggunakan neuron tiruan seperti ini untuk merancang model data yang kompleks. Sebuah neuron tiruan tunggal diilustrasikan pada Gambar 2.3 berikut.




Gambar 2.3 Neuron Tiruan Tunggal (Lantz, 2013).

Fungsi aktivasi merupakan mekanisme dimana variabel *input* dan *output* diproses dan dikirimkan ke unit lainnya dalam jaringan. Terdapat berbagai fungsi aktivasi yang dapat dipilih berdasarkan karakteristik matematis yang sesuai untuk memodelkan data. Fungsi aktivasi yang umum digunakan adalah fungsi aktivasi nonlinear seperti fungsi logistik sigmoid pada Gambar 2.4 yang diberikan dengan (Han et al, 2010):

$$O_j = \frac{1}{1 + e^{-I_j}} \quad (2.20)$$

dimana,  $O_j$  adalah *output* unit  $j$  dan  $I_j$  adalah *input* unit  $j$ .



Gambar 2.4 Fungsi Aktivasi Sigmoid.

### 2.7.2 Algoritma Backpropagation

Data yang telah diketahui keluarannya digunakan untuk melatih JST memperkirakan hubungan antara variabel *input* dan *output* dengan secara iteratif melakukan modifikasi parameter. *Backpropagation* adalah salah satu algoritma jaringan syaraf tiruan untuk mencari satu set bobot yang dapat memodelkan data sehingga dapat meminimalkan kesalahan pangkat rata-rata (*mean squared error*). Masing-masing variabel input diumpan maju ke setiap lapisan dalam jaringan dan membandingkan output dengan nilai aktual yang diketahui. Kesalahan kemudian disebarkan kembali ke semua lapisan untuk melakukan modifikasi bobot. Adapun masing-masing langkah dalam algoritma *backpropagation* adalah sebagai berikut (Han et al, 2010):

#### 1. Inisialisasi Bobot dan Bias

Bobot masing-masing unit dalam jaringan diinisialisasi dengan angka acak kecil (misalnya, mulai dari  $-1.0$  sampai  $1.0$ , atau  $-0.5$  sampai  $0.5$ ). Setiap unit memiliki bias (*intercept*) terkait yang diinisialisasi dengan cara yang sama.

#### 2. Umpan Maju (*Feed-forward*)

- Masing-masing  $x_1, x_2, x_i, \dots, x_n$  diumpan ke lapisan *input*. Data yang melalui lapisan *input* akan menghasilkan *output* tanpa ada perubahan. *Output*  $O_j$  dari masing-masing unit  $j$  pada lapisan *input* sama dengan nilai *input*  $I_j$ .
- *Input* untuk setiap unit pada lapisan tersembunyi dan lapisan *output* dihitung menggunakan kombinasi linear tertimbang:

$$I_j = \sum_i w_{ij} O_i + \theta_j \quad (2.21)$$

dimana  $w_{ij}$  adalah bobot koneksi dari unit  $i$  pada lapisan sebelumnya ke unit  $j$ ,  $O_i$  adalah output unit  $i$  dari lapisan sebelumnya, dan  $\theta_j$  bias unit  $j$ .

- Hasilnya kemudian dimodifikasi oleh fungsi aktivasi nonlinear sebelum menjadi *output*. Nilai  $O_j$  dihitung untuk setiap unit pada lapisan tersembunyi dan kemudian pada lapisan *output* untuk menghasilkan prediksi.

### 3. Penyebaran Kesalahan ke Belakang (*Backpropagation of Errors*)

- Kesalahan (*error*) disebarkan ke belakang ke semua lapisan untuk melakukan modifikasi bobot. Untuk unit  $j$  pada lapisan output, kesalahan  $Err_j$  dihitung dengan:

$$Err_j = O_j(1 - O_j)(T_j - O_j) \quad (2.22)$$

dimana,  $O_j$  adalah *output* unit  $j$ , dan  $T_j$  adalah nilai aktual pada data latih.

- Kesalahan (*error*) unit  $j$  pada lapisan tersembunyi dihitung dengan:

$$Err_j = O_j(1 - O_j) \sum_k Err_k w_{jk} \quad (2.23)$$

dimana,  $w_{jk}$  adalah bobot koneksi dari unit  $j$  ke unit  $k$ , dan  $Err_k$  adalah error unit  $k$ .

- Bobot dimodifikasi untuk merefleksikan kesalahan yang telah disebarkan. Modifikasi bobot dihitung menggunakan:

$$\Delta w_{ij} = (l) Err_j O_i \quad (2.24)$$

$$w_{ij} = w_{ij} + \Delta w_{ij} \quad (2.25)$$

- Bias dimodifikasi menggunakan:

$$\Delta \theta_{ij} = (l) Err_j \quad (2.26)$$

$$\theta_{ij} = \theta_{ij} + \Delta \theta_{ij} \quad (2.27)$$

Variabel  $l$  adalah parameter *learning rate* yang menentukan seberapa besar bobot dan bias di modifikasi. Semakin besar  $l$  maka semakin cepat konvergen ke minimum namun dengan kemungkinan terjadinya divergen. Semakin kecil maka semakin lambat mencapai konvergen.

### 4. Kondisi Pemberhentian

Iterasi akan berhenti apabila salah satu kondisi berikut terpenuhi:

- Semua  $\Delta w_{ij}$  pada iterasi sebelumnya adalah sangat kecil dibawah suatu ambang batas tertentu.
- Persentase kesalahan dibawah suatu ambang batas tertentu.
- Jumlah iterasi maksimum yang telah ditentukan tercapai.

Algoritma *backpropagation* dapat diringkas sebagai *pseudocode* berikut (Han et al, 2010).

**Algorithm: Backpropagation.** Neural network learning for classification or numeric prediction, using the backpropagation algorithm.

**Input:**

- $D$ , a data set consisting of the training tuples and their associated target values;
- $l$ , the learning rate;
- $network$ , a multilayer feed-forward network.

**Output:** A trained neural network.

**Method:**

- (1) Initialize all weights and biases in  $network$ ;
- (2) **while** terminating condition is not satisfied {
- (3)     **for** each training tuple  $X$  in  $D$  {
- (4)         // Propagate the inputs forward:
- (5)         **for** each input layer unit  $j$  {
- (6)              $O_j = I_j$ ; // output of an input unit is its actual input value
- (7)         **for** each hidden or output layer unit  $j$  {
- (8)              $I_j = \sum_i w_{ij} O_i + \theta_j$ ; // compute the net input of unit  $j$  with respect to the previous layer,  $i$
- (9)              $O_j = \frac{1}{1+e^{-I_j}}$ ; } // compute the output of each unit  $j$
- (10)         // Backpropagate the errors:
- (11)         **for** each unit  $j$  in the output layer
- (12)              $Err_j = O_j(1 - O_j)(T_j - O_j)$ ; // compute the error
- (13)         **for** each unit  $j$  in the hidden layers, from the last to the first hidden layer
- (14)              $Err_j = O_j(1 - O_j) \sum_k Err_k w_{jk}$ ; // compute the error with respect to the next higher layer,  $k$
- (15)         **for** each weight  $w_{ij}$  in  $network$  {
- (16)              $\Delta w_{ij} = (l) Err_j O_i$ ; // weight increment
- (17)              $w_{ij} = w_{ij} + \Delta w_{ij}$ ; } // weight update
- (18)         **for** each bias  $\theta_j$  in  $network$  {
- (19)              $\Delta \theta_j = (l) Err_j$ ; // bias increment
- (20)              $\theta_j = \theta_j + \Delta \theta_j$ ; } // bias update
- (21)         } }

## 2.8 Neural Network Autoregression (NAR)

*Neural Network Autoregression* (NAR) adalah model hibrida sederhana yang menggabungkan autoregresi dan jaringan syaraf tiruan. Untuk peramalan deret waktu univariat, nilai variabel lag dapat digunakan sebagai input ke sistem Jaringan Syaraf Tiruan (JST) untuk menghasilkan autoregresi nonlinear, hampir sama seperti dalam model autoregresi dimana variabel lag digunakan dalam regresi linear (Hyndman & Athanasopoulos, 2013). Pendekatan ARIMA untuk prediksi

deret waktu mengasumsikan bahwa data yang diteliti dihasilkan dari proses linear. JST adalah metode *data-driven* dan *self-adaptive* dimana model yang dihasilkan ditentukan oleh karakteristik yang terdapat pada data itu sendiri. Ide dasar dari pendekatan multi-model ini adalah memanfaatkan kemampuan unik masing-masing komponen model untuk lebih dapat menangkap pola yang berbeda dalam data.


Khashei (2010) menunjukkan bahwa integrasi model yang berbeda dapat menjadi cara yang efektif untuk meningkatkan kinerja pada model prediksi, terutama ketika model yang digunakan cukup berbeda. Penelitian yang dilakukannya menggabungkan model hibrida ARIMA dan JST pada tiga data deret waktu termasuk data nilai tukar valuta asing GBP/USD. Pada tahap pertama, model ARIMA diestimasi untuk menghasilkan ARIMA(p,d,q). Variabel lag dari orde AR dan MA kemudian masing-masing digunakan sebagai masukan ke dalam sistem JST *multilayer feed-forward* dengan satu lapisan tersembunyi. Hasil evaluasi akurasi peramalan menunjukkan *Mean Absolute Error* (MAE) dan *Mean Squared Error* (MSE) model hibrida lebih kecil dibandingkan model ARIMA dan JST.

## BAB 3

### METODE PENELITIAN

#### 3.1 Diagram Alir Penelitian

Adapun diagram alir penelitian diberikan pada Gambar 3.1 berikut.




Gambar 3.1 Diagram Alir Penelitian.

### 3.2 Data dan Variabel Penelitian

Variabel penelitian adalah deret waktu univariat  $y_1, y_2, \dots, y_T$  yang merupakan sampel data harga penutupan harian IHSG periode Januari 2010 - Desember 2014. Pengumpulan data sekunder dilakukan dengan mengunduh data harian IHSG dari <http://finance.yahoo.com>. IHSG adalah indeks kapitalisasi-pasar tertimbang dengan waktu dasar 10 Agustus 1982 yang terdiri dari 325 perusahaan yang terdaftar di BEI.

### 3.3 Pengolahan Data

Pengolahan data dilakukan untuk memeriksa apakah terdapat *outlier* dan *missing* data. Imputasi data kemudian dilakukan untuk menghasilkan dataset awal yang lengkap. Data kemudian dibagi menggunakan metode *hold out* seperti pada Gambar 3.2 berikut.



Gambar 3.2 Metode *Hold Out*.

- (1) 80% untuk set data *training* yang digunakan dalam estimasi model.
- (2) 20% untuk set data *test* yang digunakan dalam evaluasi akurasi model.

### 3.4 Pemodelan Box-Jenkins

Diagram alir pada Gambar 3.1 mengadopsi tahap-tahap yang dilakukan dalam pemodelan Box-Jenkins. Adapun tahap-tahap pemodelan adalah: (1) Tahap Identifikasi, (2) Tahap Estimasi, (3) Tahap Diagnostik. Setelah model ARIMA yang sesuai didapatkan maka peramalan untuk beberapa periode ke depan dapat dihasilkan. Tahap terakhir adalah melakukan evaluasi akurasi peramalan dengan mengukur kesalahan antara nilai yang diramalkan dengan nilai aktual.



### 3.4.1 Tahap Identifikasi

Tahap pertama dalam pemodelan Box-Jenkins adalah menentukan apakah deret waktu adalah stasioner dan jika ada tren yang signifikan yang perlu dimodelkan. Dasar untuk setiap analisis deret waktu adalah asumsi bahwa deret waktu adalah stasioner dalam *mean* dan *varians*. Stasioneritas dideteksi secara visual menggunakan plot deret waktu, plot fungsi autokorelasi (ACF), dan dengan menggunakan uji stasioneritas *Augmented Dickey-Fuller* (ADF). Deret waktu nonstasioner akan menunjukkan ACF yang signifikan yang menurun dengan sangat lambat, dan uji ADF akan menunjukkan deret waktu mempunyai akar unit. Transformasi Box-Cox dan diferensiasi kemudian dilakukan untuk menghasilkan deret waktu yang stasioner dalam *mean* dan *varians*.

### 3.4.2 Tahap Estimasi

*Maximum likelihood estimation* (MLE) merupakan metode pendugaan parameter yang memaksimalkan probabilitas model yang dihasilkan sesuai dengan data. Estimasi parameter  $c, \phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q$  untuk model ARIMA diperoleh dengan meminimumkan:

$$\frac{1}{2T} \sum_{t=1}^T \varepsilon_t^2 = \frac{1}{2T} \sum_{t=1}^T (y_t - c - \phi_1 y_{1,t} - \dots - \phi_k y_{k,t})^2 \quad (3.1)$$

*Akaike Information Criterion* (AIC) merupakan kriteria *goodness of fit* yang digunakan untuk mengukur *how well the estimated model fits the data*. Orde  $p$  dan  $q$  yang menghasilkan model ARIMA terbaik adalah yang memiliki AIC terkecil. AIC untuk model ARIMA diberikan sebagai:

$$AIC = -2 \log(L) + 2(p + q + k + 1) \quad (3.2)$$

dimana,

$L = \text{likelihood data}$ ,

$k = 1$  jika  $c \neq 0$ , dan  $k = 0$  jika  $c = 0$ .

Estimasi dilakukan menggunakan bantuan program komputer yang mengimplementasikan algoritma pemodelan ARIMA yang optimal secara otomatis.

Adapun algoritma dalam estimasi model ARIMA adalah sebagai berikut (Hyndman & Khandakar, 2008):

1. Menentukan empat model awal sebagai berikut:
  - ARIMA(0,d,0)
  - ARIMA(1,d,0)
  - ARIMA(0,d,1)
  - ARIMA(2,d,2)
2. Melakukan estimasi parameter  $c, \phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q$  dengan *Maximum Likelihood Estimation* (MLE).
3. Menghitung *Akaike Information Criterion* (AIC).
  - Model terbaik adalah model dengan AIC terkecil.
  - Jika  $d = 0$  maka set  $c \neq 0$ . Jika  $d \geq 1$  maka set  $c = 0$ .
4. Mencoba variasi p dan q sebesar  $\pm 1$  pada model terbaik.
5. Ulangi langkah 2-4 sampai tidak ada AIC yang lebih kecil.

### 3.4.3 Tahap Diagnostik

Tahap diagnostik dilakukan untuk memeriksa apakah model ARIMA yang dihasilkan telah memenuhi persyaratan sebagai berikut:

1. Mempunyai parameter yang signifikan.
2. Residual mempunyai rata-rata nol dan tidak berkorelasi.
3. Residual berdistribusi normal.

#### 3.4.3.1 Uji Signifikansi Parameter

Uji signifikansi parameter dilakukan untuk memeriksa apakah parameter yang dihasilkan pada tahap estimasi adalah signifikan yang didasarkan pada:

Hipotesis:

$H_0$  : parameter = 0

$H_a$  : parameter  $\neq 0$

Statistik uji:

$$t = \frac{\hat{\phi}_p}{SE(\hat{\phi}_p)} \text{ atau } t = \frac{\hat{\theta}_q}{SE(\hat{\theta}_q)} \quad (3.3)$$

Daerah penolakan:

Tolak  $H_0$  jika  $|t| > t_{\alpha/2, n-p}$  atau p-value  $< \alpha$  sebesar 5% .

Dimana,

n = banyaknya observasi

p = jumlah parameter

### 3.4.3.2 Uji Asumsi *White Noise* Residual

Uji Ljung-Box dilakukan untuk memeriksa apakah residual model memenuhi asumsi *white noise*, sehingga tidak bias dan tidak ada lagi informasi yang tersisa yang dapat dimodelkan. Deret waktu yang tidak mempunyai autokorelasi disebut dengan "*white noise*". *White noise* adalah proses deret waktu stasioner dengan  $E(\mu) = 0$  dan koefisien autokorelasi yang diharapkan mendekati nol dan berada di dalam batas nilai kritis  $\pm 2/\sqrt{T}$ . Uji Ljung-Box didasarkan pada:

Hipotesis:

$H_0 : r_i = 0, i=1,2,...,K$  (residual adalah white noise)

$H_a : \text{Minimal ada satu } r_i \neq 0, i=1,2,...,K$  (residual tidak white noise)

Statistik uji:

$$Q^* = T(T+2) \sum_{k=1}^h (T-k)^{-1} r_k \quad (3.4)$$

Daerah penolakan: Tolak  $H_0$  jika  $Q^* > \chi^2_{\alpha, h-K}$  atau p-value  $< \alpha$  .

### 3.4.3.3 Uji Normalitas Residual

Uji normalitas Kolmogorov-Smirnov dilakukan untuk memeriksa apakah residual berdistribusi normal sehingga interval peramalan yang dihasilkan adalah absah. Uji Kolmogorov-Smirnov didasarkan pada:

Hipotesis:

$H_0 = F(x) = F_0(x)$  untuk semua nilai x

$H_a = F(x) \neq F_0(x)$  untuk sekurang-kurangnya sebuah nilai x

Statistik uji:

$$D = \sup_x |S(x) - F_0(x)| \quad (3.5)$$

Daerah penolakan:

Tolak  $H_0$  jika  $D > D_{1-\alpha,n}$  atau p-value  $< \alpha$ .

### 3.5 Peramalan Random Walk with Drift

Model *Random Walk with drift* pada dasarnya adalah model ARIMA(0,1,0). Sebagian besar pergerakan harga saham di pasar efisien mengikuti proses ini. Peramalan diperoleh sebagai berikut:

$$y_T + \frac{h}{T-1} \sum_{t=2}^n (y_t - y_{t-1}) = y_n + h \left( \frac{y_T - y_1}{T-1} \right) \quad (3.6)$$

dimana,

$y_T$  = pengamatan terakhir

$h$  = periode peramalan

### 3.6 Peramalan ARIMA

Setelah estimasi model ARIMA didapatkan, peramalan untuk satu atau beberapa periode ke depan kemudian dapat dilakukan. Hasil dari peramalan adalah estimasi nilai dari variabel acak yang akan diramalkan (*point forecast*). Peramalan ARIMA dapat disertai dengan interval prediksi yang memberikan rentang nilai variabel dengan probabilitas tertentu (*interval forecast*). Interval peramalan mengasumsikan bahwa *error* peramalan tidak mempunyai korelasi dan berdistribusi normal. Perhitungan interval peramalan diberikan dengan:

$$\hat{y}_t = \pm t_{\alpha/2} \hat{\sigma} \quad (3.7)$$

dimana,

$\hat{y}_t$  = estimasi  $y$  pada waktu  $t$

$t_{\alpha/2}$  = nilai  $t$  dengan selang kepercayaan  $\alpha$

$\hat{\sigma}$  = simpangan baku residual

### 3.7 Pemodelan Neural Network Autoregression (NAR)

*Neural Network Autoregression* menggunakan variabel lag sebagai *input* ke dalam sistem jaringan syaraf tiruan. Adapun langkah-langkah dalam pemodelan NAR adalah sebagai berikut:

#### 1) Pengolahan Data Variabel Lag

Untuk pemodelan NAR metode pengolahan yang digunakan adalah sama seperti dalam pemodelan ARIMA, namun dilakukan pengolahan lebih lanjut untuk menghasilkan dataset yang menyertakan variabel lag dan sesuai dengan format yang digunakan paket *neuralnet* pada program R. Normalisasi data kemudian dilakukan untuk menghasilkan data dengan rata-rata nol dan simpangan baku satu. Hal ini bertujuan agar algoritma *backpropagation* dapat lebih cepat konvergen menghasilkan bobot dengan kesalahan terkecil.

#### 2) Menentukan Topologi Jaringan

Jumlah lag dari orde AR yang dihasilkan dari estimasi ARIMA digunakan sebagai *input* ke dalam sistem *Multilayer Feed-forward* dengan satu lapisan tersembunyi dan satu lapisan *output*. Sistem JST ini memodelkan hubungan antara variabel *input* berupa variabel lag  $y_{t-1}, y_{t-2}, y_{t-3}$  dan variabel *output*  $y_t$ . Tidak ada aturan baku untuk menentukan jumlah unit dalam lapisan tersembunyi dan menggunakan jumlah unit yang sama dengan lapisan *input* akan menghasilkan model yang cukup memadai. Jumlah unit dalam lapisan tersembunyi yang ditentukan adalah jumlah unit dalam lapisan *input* ditambah satu unit.

#### 3) Estimasi dan Diagnostik

Algoritma *backpropagation* dijalankan untuk menghasilkan estimasi parameter model dengan kesalahan terkecil. Diagnostik residual kemudian dilakukan untuk memeriksa apakah kesalahan yang dihasilkan mempunyai rata-rata nol. Setelah hasil uji diagnostik memuaskan maka model dapat digunakan untuk prediksi pada dataset *testing*.

### 3.8 Evaluasi Akurasi Peramalan

*Error* peramalan adalah perbedaan antara nilai yang diramalkan dengan nilai sebenarnya dan diberikan dengan,  $e_i = y_i - \hat{y}_i$ . Akurasi model peramalan diukur menggunakan:

1. *Mean Absolute Error* (MAE):

$$\text{MAE} = \text{mean}(|e_i|) \quad (3.8)$$

2. *Root Mean Squared Error* (RMSE):

$$\text{RMSE} = \sqrt{\text{mean}(e_i^2)} \quad (3.9)$$

3. *Mean Absolute Percentage Error* (MAPE):

Persentase *error* diberikan dengan  $p_i = 100e_i/y_i$ . MAPE mempunyai kelebihan yaitu tidak tergantung pada skala data sehingga dapat digunakan untuk mengukur beberapa model yang menggunakan data dengan skala berbeda. MAPE dihitung dengan:

$$\text{MAPE} = \text{mean}(|p_i|) \quad (3.10)$$

### 3.9 Perangkat Lunak Yang Digunakan

R adalah perangkat lunak bebas GNU untuk komputasi statistik dan grafis. Versi R yang digunakan adalah versi 3.0.2 ("*Frisbee Sailing*") yang dijalankan pada sistem operasi Windows. Ada sekitar delapan paket yang disertakan dengan distribusi R dan banyak lagi yang tersedia melalui situs internet CRAN dan berbagai *mirror*. Adapun paket tambahan yang digunakan dalam penelitian ini diberikan pada Tabel 3.1.

Tabel 3.1 Paket R yang digunakan.

Paket R	Keterangan
<i>forecast</i> versi 5.8	Metode dan fungsi untuk melakukan analisis deret waktu.
<i>quantmod</i> versi 0.4-0	Metode dan fungsi untuk strategi perdagangan kuantitatif berbasis statistik.
<i>neuralnet</i> versi 1.3.2	Metode dan fungsi untuk melatih jaringan syaraf tiruan.

## BAB 4

### HASIL DAN PEMBAHASAN

#### 4.1 Pergerakan Indeks Harga Saham Gabungan

Pergerakan Indeks Harga Saham Gabungan (IHSG) selama periode pengamatan menunjukkan tren yang naik tanpa ada pola musiman. Terdapat beberapa sub periode dengan tren naik yang kuat dan beberapa subperiode dimana IHSG berfluktuasi. IHSG mencapai level tertinggi diatas 5.000 pada awal pertengahan tahun 2013 yang diikuti oleh penurunan yang tajam sampai kembali ke level sedikit diatas 4.000 pada akhir tahun 2014. IHSG berhasil pulih ke level 5.000 di akhir tahun 2014. Pergerakan IHSG ditunjukkan pada Gambar 4.1.



Gambar 4.1. IHSG Periode Januari 2010 - Desember 2014.

#### 4.2 Statistik Deskriptif

Selama periode pengamatan data IHSG menunjukkan nilai terendah pada level 2.476 dan tertinggi level 5.215. Dalam kurun 4 tahun IHSG mengalami pertumbuhan lebih dari 250%. Simpangan baku sebesar 628.40 menunjukkan fluktuasi harian IHSG. Statistik deskriptif selama periode pengamatan diberikan pada Tabel 4.1.


Tabel 4.1 Statistik Deskriptif IHSG Periode Januari 2010 - September 2014.

<i>Minimum</i>	<i>1st.Qu</i>	<i>Median</i>	<i>Mean</i>	<i>3rd.Qu</i>	<i>Maximum</i>	<i>Std. Dev</i>
2476	3530	3860	3838	4256	5215	628.40

Sumber: Hasil Penelitian.

### 4.3 Fungsi Autokorelasi

Karena stasioneritas adalah esensial untuk identifikasi model ARIMA, maka langkah pertama adalah menguji stasioneritas. Uji stasionaritas dilakukan secara visual menggunakan plot fungsi autokorelasi ACF dan dengan uji stasioneritas *Augmented* Dickey-Fuller (ADF). Dari plot fungsi autokorelasi pada Gambar 4.2 terlihat bahwa deret waktu IHSG nonstasioner dan menunjukkan autokorelasi signifikan di atas batas kritis yang menurun dengan sangat lambat.



Gambar 4.2 Plot Fungsi Autokorelasi.


### 4.4 Uji *Augmented* Dickey-Fuller

Hasil uji *Augmented* Dickey-Fuller (ADF) menunjukkan nilai  $ADF = -3.0376$  dengan lag order = 9 gagal menolak hipotesis nul bahwa deret waktu nonstasioner dengan p-value 0.1391. Deret waktu IHSG mempunyai akar unit dan nonstasioner sehingga memerlukan diferensiasi.

### 4.5 Transformasi Box-Cox

Untuk memeriksa apakah deret waktu nonstasioner dalam varians maka digunakan plot Box-Cox. Gambar 4.3 menunjukkan bahwa parameter transformasi lambda dengan standar deviasi minimum adalah yang berada pada batas *Lower* CL = 0.33 dan *Upper* CL = 0.93, dengan estimasi terbaik = 0.64 dan *rounded value* = 0.5. Batas *lower* dan *upper* CL tidak mencakup nilai  $\lambda = 1$  yang menunjukkan bahwa deret waktu nonstasioner dalam varians.






Gambar 4.3 Box-Cox plot data IHSG.

Hasil transformasi deret waktu menggunakan  $(y_t^\lambda - 1)/\lambda$  dengan  $\lambda = 0.35$  menghasilkan deret waktu dengan varians konstan.

#### 4.6 Diferensiasi Deret Waktu

Deret waktu setelah dilakukan transformasi sudah stasioner dalam varians namun perlu dilakukan diferensiasi untuk menghasilkan deret waktu yang stasioner dalam *mean*. Diferensiasi tingkat 1 menghasilkan deret waktu stasioner seperti ditunjukkan pada Gambar 4.4 sebagai berikut.




Gambar 4.4 Diferensiasi Tingkat 1.

Uji stasioneritas ADF setelah diferensiasi dan transformasi menghasilkan nilai -8.89 dan menolak hipotesis nul dengan p-value lebih kecil dari 0.01. Hal ini berarti deret waktu tidak mempunyai akar unit dan stasioner dalam *mean*.

#### 4.7 Identifikasi Fungsi Autokorelasi dan Autokorelasi Parsial

Setelah deret waktu stasioner dalam *mean* dan *variance*, identifikasi model menggunakan ACF dan PACF dengan batas kritis  $\pm 1.96/\sqrt{T}$ . Plot ACF pada Gambar 4.5a menunjukkan 2 autokorelasi yang signifikan. Plot PACF pada Gambar 4.5b menunjukkan 3 autokorelasi parsial yang signifikan. Hal ini mengisyaratkan deret waktu mempunyai karakteristik Autoregresi AR(3) dan *Moving Average* MA(2).



Gambar 4.5a ACF dan 4.5b PACF Setelah Transformasi dan Diferensiasi.

#### 4.8 Estimasi Model

Estimasi menggunakan program R menghasilkan ARIMA(3,1,2) dengan koefisien drift positif. Hal ini berarti bahwa autokorelasi dengan lag 3 dan kesalahan dengan lag 2 dapat digunakan untuk peramalan pergerakan IHSG. Koefisien drift positif menunjukkan tren yang naik. *Output* hasil estimasi dan koefisien diberikan pada Gambar 4.6.

```
Console D:/9110205441-tesis/R/Adit Forecast IHSG/
> print(arimafit)
Series: traindata
ARIMA(3,1,2) with drift
Box Cox transformation: lambda= 0.35

Coefficients:
          ar1          ar2          ar3          ma1          ma2          drift
0.2004876 -0.4345926 -0.1266514 -0.1611720 0.3630927 0.0127591
s.e. 0.2105819 0.1401086 0.0462241 0.2120162 0.1386509 0.0078586

sigma^2 estimated as 0.0630398: log likelihood=-28.96
AIC=71.93 AICc=72.07 BIC=104.69
```

Gambar 4.6 *Output* Hasil Estimasi Model ARIMA.

#### 4.8.1 Uji Signifikansi Parameter

Hasil uji signifikansi parameter model ARIMA(3,1,2) pada Tabel 4.2 menunjukkan bahwa semua parameter berada di dalam selang kepercayaan 95% dan p-values yang menunjukkan bahwa semua parameter signifikan kecuali koefisien drift.


Tabel 4.2 Hasil Uji Signifikansi Parameter model ARIMA(3,1,2).

	Koefisien	2.5%	97.5%	p-value	Signifikan
AR 1	0.2005	0.0017	0.8272	0.0034	Ya
AR 2	-0.4346	-0.7092	-0.1599	0.0019	Ya
AR 3	-0.1266	-0.2172	-0.0360	0.0061	Ya
MA 1	-0.1612	-0.8767	-0.0456	0.0471	Ya
MA 2	0.3631	0.0913	0.6348	0.0088	Ya
Drift	0.0127	-0.0026	0.0282	0.1045	Tidak

Sumber: Hasil Penelitian.

#### 4.8.2 Diagnostik Residual ARIMA(3,1,2)

Plot residual pada Gambar 4.7a menunjukkan bahwa peramalan menghasilkan residual stasioner dengan *mean* nol. ACF residual pada Gambar 4.7b juga menunjukkan tidak ada autokorelasi yang signifikan. Secara visual terlihat bahwa peramalan menghasilkan residual stasioner dengan *mean* nol dan memenuhi asumsi *white noise*.



Gambar 4.7a Residual dan Gambar 4.7b ACF Residual,

#### 4.8.2.1 Uji Stasioneritas Residual


Hasil uji *Augmented* Dickey-Fuller menghasilkan nilai -8.739 dengan p-value lebih kecil dari 0.01 yang menolak hipotesis nul bahwa residual nonstasioner. Hasil uji memberikan konfirmasi bahwa peramalan menghasilkan residual stasioner dengan *mean* nol yang berarti bahwa peramalan tidak bias.

#### 4.8.2.2 Uji Asumsi *White Noise* Residual

Uji Ljung-Box menghasilkan nilai X-squared = 2.7295 dengan p-value 0.7416 tidak menolak hipotesis nul bahwa residual adalah *white noise*. Hasil uji memberikan konfirmasi bahwa residual peramalan secara keseluruhan tidak mempunyai autokorelasi yang signifikan dan memenuhi asumsi *white noise*. Hal ini berarti bahwa model yang dihasilkan sudah efisien dan tidak ada lagi informasi pada residual yang dapat digunakan untuk peramalan.

#### 4.8.2.3 Uji Normalitas Residual


Histogram pada Gambar 4.8a dan normal plot pada Gambar 4.8b menunjukkan bahwa residual terpusat sekitar nol dan berdistribusi leptokurtik dengan nilai kurtosis 6.48. Selain itu nampak bahwa histogram mempunyai *skewness* -1.08. Secara visual terlihat bahwa residual tidak berdistribusi normal. Hasil uji Kolmogorov-Smirnov memberi konfirmasi menolak hipotesis nul residual berdistribusi normal dengan p-value 0.0009. Hasil uji normalitas memberikan indikasi bahwa interval peramalan tidak valid.



Gambar 4.8a Histogram Residual dan Gambar 4.8b Normal Plot Residual.

#### 4.9 Peramalan *Random Walk*


Plot hasil peramalan *random walk* dengan koefisien drift 2.5698 dan interval 80% dan 95% ditunjukkan pada Gambar 4.9. *Random walk* menghasilkan peramalan berupa tren naik dengan interval peramalan yang semakin melebar.



Gambar 4.9 Peramalan *Random Walk with Drift*.

#### 4.10 Peramalan ARIMA(3,1,2)


Plot hasil peramalan ARIMA(3,1,2) dengan interval 80% dan 95% ditunjukkan pada Gambar 4.10. ARIMA(3,1,2) menghasilkan peramalan berupa tren naik dengan interval peramalan yang sedikit lebih sempit dibandingkan model *random walk*.



Gambar 4.10 Peramalan ARIMA(3,1,2).

#### 4.11 Model Neural Network Autoregression

Pemodelan Box-Jenkins menghasilkan ARIMA(3,1,2) dengan autoregresi AR(3). Hal ini berarti bahwa variabel lag 3 mempunyai autokorelasi yang signifikan yang dapat digunakan untuk peramalan. Model *Neural Network Autoregression* yang dihasilkan yaitu NAR(3) yang berupa *multilayer feed-forward* yang memodelkan hubungan antara tiga unit *input* berupa variabel lag  $y_{t-1}, y_{t-2}, y_{t-3}$ , 4 unit lapisan tersembunyi dan satu unit *output* yaitu  $y_t$ . Lapisan *input* dan lapisan tersembunyi masing-masing mempunyai satu unit bias yang selalu mempunyai keluaran satu. Algoritma *backpropagation* dijalankan pada program untuk menghasilkan bobot dengan kesalahan minimum 2.05972 yang dicapai dalam 10682 *steps*. Hasil estimasi model diberikan pada Gambar 4.11.



Gambar 4.11 *Neural Network Autoregression* NAR(3) menggunakan 3 variabel lag sebagai *input*.

Bobot masing-masing unit yang dihasilkan dalam lapisan tersembunyi diberikan pada Tabel 4.3 dan bobot unit *output* diberikan pada Tabel 4.4.

Tabel 4.3 Bobot Unit dalam Lapisan Tersembunyi.

	Unit 1	Unit 2	Unit 3	Unit 4
w1	-2.6525	0.8058	-0.7872	-0.3695
w2	-1.0461	-0.8194	0.6951	1.2356
w3	0.6978	3.1625	0.1656	1.7915
w4	-1.1374	-3.7473	-0.3693	-2.3367

Sumber: Hasil Penelitian.

Tabel 4.4 Bobot Unit *Output*.

	w1	w2	w3	w4	w5
<b>Unit Output</b>	-0.29705	-0.29705	-0.29705	-0.29705	-0.29705

Sumber: Hasil Penelitian.

#### 4.11.1 Uji Signifikansi Parameter

Hasil uji signifikansi parameter model NAR(3) dengan selang kepercayaan 95% menunjukkan bahwa hampir semua parameter tidak signifikan. Hasil uji signifikansi parameter diberikan pada Tabel 4.5 dan Tabel 4.6.

Tabel 4.5 Uji Signifikansi Bobot Unit Lapisan tersembunyi

	Unit 1		Unit 2		Unit 3		Unit 4	
	Lower	Upper	Lower	Upper	Lower	Upper	Lower	Upper
w1	-9.2113	3.9062	-2.2811	3.8928	-5.3133	3.7388	-0.9426	0.2036
w2	-5.6374	3.5451	-2.0410	0.4022	-2.9731	4.3634	-1.0158	3.4871
w3	-0.7952	2.1909	-2.3677	8.6928	-5.4208	5.7520	0.3382	3.2449
w4	-2.5549	0.2802	-10.751	3.2563	-8.8604	8.1217	-2.9300	-1.7435

Sumber: Hasil Penelitian.


Tabel 4.6 Uji Signifikansi Bobot Unit *Output*.

	w1		w2		w3		w4		w5	
	Lower	Upper	Lower	Upper	Lower	Upper	Lower	Upper	Lower	Upper
<b>Unit Output</b>	-1.483	0.889	-8.590	5.144	-3.024	0.511	0.714	3.439	-4.146	7.206

Sumber: Hasil Penelitian.

#### 4.11.2 Diagnostik Residual

Plot residual pada Gambar 4.12a menunjukkan bahwa peramalan NAR(3) menghasilkan residual stasioner dengan *mean* nol. ACF residual pada Gambar 4.12b juga menunjukkan tidak ada autokorelasi yang signifikan. Secara visual terlihat bahwa peramalan NAR(3) menghasilkan residual stasioner dengan *mean* nol dan memenuhi asumsi *white noise*.



Gambar 4.12a Residual dan Gambar 4.12b ACF Residual Model NAR(3).

#### 4.11.3 Uji Stasioneritas Residual

Hasil uji *Augmented* Dickey-Fuller menghasilkan nilai -8.3788 dengan p-value lebih kecil dari 0.01 yang menolak hipotesis nul bahwa residual nonstasioner. Hasil uji memberikan konfirmasi bahwa peramalan menghasilkan residual stasioner dengan *mean* nol yang berarti bahwa peramalan tidak bias.


#### 4.11.4 Uji Asumsi *White Noise* Residual

Uji Ljung-Box menghasilkan nilai X-squared = 0.0398 dengan p-value 0.8419 tidak menolak hipotesis nul bahwa residual adalah *white noise*. Hasil uji memberikan konfirmasi bahwa residual peramalan secara keseluruhan tidak mempunyai autokorelasi yang signifikan dan memenuhi asumsi *white noise*.



#### 4.12 Peramalan NAR(3)

Plot pada Gambar 4.13 membandingkan hasil peramalan dan nilai aktual pada data *testing*. Garis hitam menunjukkan nilai aktual dan garis biru menunjukkan hasil prediksi. Hasil menunjukkan bahwa model ini dapat melakukan prediksi dengan akurat.



Gambar 4.13 Peramalan NAR(3).

#### 4.13 Evaluasi Akurasi Peramalan

Hasil evaluasi menunjukkan bahwa peramalan NAR(3) pada data *testing* menghasilkan akurasi yang lebih baik dari model lainnya yang ditunjukkan oleh nilai MAE, RMSE dan MAPE yang lebih kecil. Akurasi yang tinggi ini menunjukkan bahwa NAR nampaknya *overfitting* dan kurang menghasilkan generalisasi yang baik. Hasil evaluasi akurasi diberikan pada Tabel 4.7.

Tabel 4.7. Hasil Evaluasi Akurasi Peramalan.

Neural Network Autoregression		MAE	RMSE	MAPE
Training		36.8590	53.3964	0.9731
Testing		39.3889	49.1414	0.7861
ARIMA(3,1,2)		MAE	RMSE	MAPE
Training		37.1383	54.0115	0.9839
Testing		112.6283	127.4124	2.9917
Random Walk		MAE	RMSE	MAPE
Training		37.4336	55.0888	0.9899
Testing		121.3982	148.1911	2.4130

Sumber: Hasil Penelitian.

## BAB 5

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Dari hasil pemodelan Box-Jenkins (ARIMA) untuk peramalan Indeks Harga Saham Gabungan (IHSG), kesimpulan yang dapat diambil adalah:

1. Indeks Harga Saham Gabungan (IHSG) selama periode pengamatan menunjukkan tren yang naik dan autokorelasi yang signifikan. Pergerakan harga saham di Bursa Efek Indonesia (BEI) tidak mengikuti proses *random walk* dan tidak sesuai dengan hipotesis pasar-efisien.
2. Estimasi model pada data *training* menghasilkan ARIMA(3,1,2) dengan koefisien drift sebagai berikut:

$$(1 - 0.2004B + 0.4345B^2 + 0.1266B^3)(1 - B) y_t = 0.0127 + (1 - 0.1611B + 0.3631B^2) \varepsilon_t$$

dengan nilai *sigma squared* = 0.0630, nilai *log likelihood* = -28.96, dan nilai *Akaike Information Criterion*, AIC = 71.93.

Semua parameter signifikan kecuali drift.

3. Peramalan menghasilkan residual stasioner dengan *mean nol* yang berarti memenuhi asumsi *white noise*.
4. ARIMA(3,1,2) menghasilkan peramalan untuk 200 hari. *Point forecast* menghasilkan peramalan berupa tren naik yang sesuai dengan koefisien drift positif. *Interval forecast* dengan selang 80% dan 95% menghasilkan interval peramalan yang semakin melebar.
5. *Neural Network Autoregression* menggunakan 3 lag autoregresi sebagai *input* ke sistem jaringan syaraf tiruan dengan satu *hidden layer* yang terdiri dari 4 unit menghasilkan model peramalan NAR(3). Prediksi dihasilkan pada dataset *testing* untuk 200 hari dengan akurasi yang tinggi.

6. Evaluasi akurasi pada dataset *testing* menggunakan *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) menunjukkan bahwa model NAR(3) menghasilkan kesalahan peramalan terkecil dengan akurasi yang berada dalam kisaran 98%. Hasil evaluasi akurasi ini menunjukkan bahwa NAR(3) nampaknya *overfitting* dan kurang menghasilkan generalisasi yang baik.
7. Peramalan ARIMA berupa tren kiranya lebih sesuai untuk peramalan di pasar saham yang sangatf luktuatif dan penuh dengan ketidakpastian. Hal ini sesuai dengan peribahasa yang mengatakan bahwa "*The Trend is your Friend, Until It Bends*".

## 5.2 Saran

Beberapa saran yang dapat diberikan untuk perbaikan model peramalan dan pengembangan adalah:

1. Menambah jumlah data dan menggunakan metode *Walk-Forward Optimization*.
2. Memperbaiki Jaringan Syaraf Tiruan (JST) untuk menghasilkan model peramalan dengan generalisasi yang lebih baik.
2. Menggunakan *Vector Autoregression* (VAR) dan *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH).
3. Mengembangkan strategi perdagangan otomatis berdasarkan model peramalan.

## BAB 5

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Dari hasil pemodelan Box-Jenkins (ARIMA) untuk peramalan Indeks Harga Saham Gabungan (IHSG), kesimpulan yang dapat diambil adalah:

1. Indeks Harga Saham Gabungan (IHSG) selama periode pengamatan menunjukkan tren yang naik dan autokorelasi yang signifikan. Pergerakan harga saham di Bursa Efek Indonesia (BEI) tidak mengikuti proses *random walk* dan tidak sesuai dengan hipotesis pasar-efisien.
2. Estimasi model pada data *training* menghasilkan ARIMA(3,1,2) dengan koefisien drift sebagai berikut:

$$(1 - 0.2004B + 0.4345B^2 + 0.1266B^3)(1 - B) y_t = 0.0127 + (1 - 0.1611B + 0.3631B^2) \varepsilon_t$$

dengan nilai *sigma squared* = 0.0630, nilai *log likelihood* = -28.96, dan nilai *Akaike Information Criterion*, AIC = 71.93.

Semua parameter signifikan kecuali drift.

3. Peramalan menghasilkan residual stasioner dengan *mean nol* yang berarti memenuhi asumsi *white noise*.
4. ARIMA(3,1,2) menghasilkan peramalan untuk 200 hari. *Point forecast* menghasilkan peramalan berupa tren naik yang sesuai dengan koefisien drift positif. *Interval forecast* dengan selang 80% dan 95% menghasilkan interval peramalan yang semakin melebar.
5. *Neural Network Autoregression* menggunakan 3 lag autoregresi sebagai *input* ke sistem jaringan syaraf tiruan dengan satu *hidden layer* yang terdiri dari 4 unit menghasilkan model peramalan NAR(3). Prediksi dihasilkan pada dataset *testing* untuk 200 hari dengan akurasi yang tinggi.

6. Evaluasi akurasi pada dataset *testing* menggunakan *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) menunjukkan bahwa model NAR(3) menghasilkan kesalahan peramalan terkecil dengan akurasi yang berada dalam kisaran 98%. Hasil evaluasi akurasi ini menunjukkan bahwa NAR(3) nampaknya *overfitting* dan kurang menghasilkan generalisasi yang baik.
7. Peramalan ARIMA berupa tren kiranya lebih sesuai untuk peramalan di pasar saham yang sangatf luktuatif dan penuh dengan ketidakpastian. Hal ini sesuai dengan peribahasa yang mengatakan bahwa "*The Trend is your Friend, Until It Bends*".

## 5.2 Saran

Beberapa saran yang dapat diberikan untuk perbaikan model peramalan dan pengembangan adalah:

1. Menambah jumlah data dan menggunakan metode *Walk-Forward Optimization*.
2. Memperbaiki Jaringan Syaraf Tiruan (JST) untuk menghasilkan model peramalan dengan generalisasi yang lebih baik.
2. Menggunakan *Vector Autoregression* (VAR) dan *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH).
3. Mengembangkan strategi perdagangan otomatis berdasarkan model peramalan.

## **DAFTAR LAMPIRAN**

LAMPIRAN 1. TABEL HASIL PERAMALAN .....	51
LAMPIRAN 2. LISTING PROGRAM .....	57
LAMPIRAN 3. <i>OUTPUT</i> HASIL UJI STATISTIK .....	63

# LAMPIRAN 1. TABEL HASIL PERAMALAN

FORECAST	ARIMA(3,1,2) WITH DRIFT					NAR(3)
Date	Point	Lo 80	Hi 80	Lo 95	Hi 95	
25-02-14	4,540.94	4,464.72	4,618.00	4,424.72	4,659.13	4,619.91
26-02-14	4,556.76	4,446.80	4,668.48	4,389.29	4,728.34	4,580.65
27-02-14	4,566.03	4,433.29	4,701.33	4,364.04	4,774.00	4,539.42
28-02-14	4,563.98	4,417.48	4,713.60	4,341.18	4,794.07	4,584.27
03-03-14	4,561.55	4,402.80	4,723.97	4,320.24	4,811.46	4,626.52
04-03-14	4,564.79	4,392.48	4,741.43	4,303.00	4,836.72	4,578.38
05-03-14	4,570.76	4,384.74	4,761.83	4,288.30	4,865.04	4,613.01
06-03-14	4,574.87	4,376.75	4,778.73	4,274.17	4,889.00	4,669.17
07-03-14	4,576.71	4,367.99	4,791.80	4,260.06	4,908.28	4,688.17
10-03-14	4,578.55	4,359.79	4,804.33	4,246.78	4,926.73	4,687.19
11-03-14	4,581.62	4,352.87	4,818.05	4,234.84	4,946.36	4,681.33
12-03-14	4,585.23	4,346.73	4,832.07	4,223.81	4,966.17	4,712.61
13-03-14	4,588.40	4,340.67	4,845.15	4,213.12	4,984.76	4,683.84
14-03-14	4,591.11	4,334.62	4,857.27	4,202.69	5,002.14	4,736.45
17-03-14	4,593.85	4,328.88	4,869.13	4,192.73	5,019.10	4,892.15
18-03-14	4,596.84	4,323.59	4,881.07	4,183.32	5,036.05	4,849.88
19-03-14	4,599.94	4,318.63	4,892.90	4,174.35	5,052.78	4,796.10
20-03-14	4,602.95	4,313.82	4,904.39	4,165.66	5,069.02	4,818.79
21-03-14	4,605.86	4,309.14	4,915.54	4,157.23	5,084.81	4,686.92
24-03-14	4,608.78	4,304.66	4,926.52	4,149.10	5,100.33	4,701.07
25-03-14	4,611.75	4,300.40	4,937.39	4,141.27	5,115.66	4,726.74
26-03-14	4,614.75	4,296.32	4,948.13	4,133.70	5,130.78	4,703.36
27-03-14	4,617.73	4,292.38	4,958.69	4,126.36	5,145.63	4,736.13
28-03-14	4,620.69	4,288.57	4,969.09	4,119.22	5,160.23	4,723.85
01-04-14	4,623.65	4,284.89	4,979.35	4,112.29	5,174.64	4,776.62
02-04-14	4,626.63	4,281.35	4,989.51	4,105.56	5,188.87	4,881.42
03-04-14	4,629.61	4,277.93	4,999.55	4,099.02	5,202.93	4,855.03
04-04-14	4,632.59	4,274.63	5,009.48	4,092.65	5,216.81	4,888.77
07-04-14	4,635.56	4,271.43	5,019.29	4,086.44	5,230.52	4,849.98
08-04-14	4,638.54	4,268.33	5,029.01	4,080.38	5,244.09	4,920.12
10-04-14	4,641.52	4,265.32	5,038.64	4,074.47	5,257.51	4,911.30
11-04-14	4,644.50	4,262.42	5,048.17	4,068.71	5,270.79	4,746.88
14-04-14	4,647.48	4,259.60	5,057.62	4,063.08	5,283.95	4,800.78
15-04-14	4,650.47	4,256.86	5,066.99	4,057.57	5,296.97	4,864.95
16-04-14	4,653.45	4,254.20	5,076.28	4,052.19	5,309.88	4,864.94
17-04-14	4,656.44	4,251.63	5,085.50	4,046.93	5,322.67	4,869.35
21-04-14	4,659.42	4,249.12	5,094.64	4,041.78	5,335.35	4,894.62

Tabel Hasil Peramalan (Lanjutan)						
22-04-14	4,662.41	4,246.69	5,103.72	4,036.73	5,347.93	4,885.97
23-04-14	4,665.40	4,244.32	5,112.73	4,031.80	5,360.41	4,892.77
24-04-14	4,668.39	4,242.03	5,121.68	4,026.96	5,372.79	4,886.83
25-04-14	4,671.39	4,239.79	5,130.57	4,022.21	5,385.08	4,885.05
28-04-14	4,674.38	4,237.61	5,139.40	4,017.56	5,397.28	4,892.45
29-04-14	4,677.37	4,235.50	5,148.17	4,013.00	5,409.39	4,807.22
30-04-14	4,680.37	4,233.44	5,156.89	4,008.52	5,421.42	4,813.43
02-05-14	4,683.37	4,231.43	5,165.56	4,004.13	5,433.37	4,841.22
05-05-14	4,686.37	4,229.48	5,174.18	3,999.82	5,445.25	4,836.27
06-05-14	4,689.37	4,227.58	5,182.75	3,995.59	5,457.04	4,841.08
07-05-14	4,692.37	4,225.73	5,191.27	3,991.43	5,468.77	4,831.87
08-05-14	4,695.37	4,223.93	5,199.74	3,987.34	5,480.42	4,862.65
09-05-14	4,698.37	4,222.17	5,208.18	3,983.32	5,492.01	4,856.85
12-05-14	4,701.38	4,220.46	5,216.57	3,979.38	5,503.54	4,897.49
13-05-14	4,704.39	4,218.79	5,224.92	3,975.50	5,515.00	4,907.43
14-05-14	4,707.39	4,217.17	5,233.23	3,971.68	5,526.39	4,914.86
16-05-14	4,710.40	4,215.59	5,241.50	3,967.93	5,537.73	4,987.67
19-05-14	4,713.41	4,214.04	5,249.73	3,964.23	5,549.01	5,018.09
20-05-14	4,716.42	4,212.54	5,257.93	3,960.60	5,560.24	4,996.44
21-05-14	4,719.43	4,211.07	5,266.09	3,957.03	5,571.41	4,870.25
22-05-14	4,722.45	4,209.65	5,274.22	3,953.51	5,582.52	4,882.56
23-05-14	4,725.46	4,208.25	5,282.31	3,950.04	5,593.59	4,966.62
26-05-14	4,728.48	4,206.90	5,290.37	3,946.63	5,604.61	4,960.26
28-05-14	4,731.50	4,205.57	5,298.40	3,943.27	5,615.57	4,950.27
30-05-14	4,734.52	4,204.28	5,306.40	3,939.96	5,626.49	4,973.28
02-06-14	4,737.54	4,203.03	5,314.37	3,936.70	5,637.36	4,875.16
03-06-14	4,740.56	4,201.80	5,322.31	3,933.49	5,648.19	4,893.23
04-06-14	4,743.58	4,200.61	5,330.22	3,930.33	5,658.98	4,937.07
05-06-14	4,746.60	4,199.45	5,338.10	3,927.21	5,669.72	4,922.47
06-06-14	4,749.63	4,198.31	5,345.96	3,924.13	5,680.42	4,925.80
09-06-14	4,752.65	4,197.21	5,353.79	3,921.10	5,691.07	4,927.89
10-06-14	4,755.68	4,196.14	5,361.59	3,918.12	5,701.69	4,872.35
11-06-14	4,758.71	4,195.09	5,369.37	3,915.17	5,712.27	4,939.08
12-06-14	4,761.74	4,194.07	5,377.13	3,912.27	5,722.81	4,962.11
13-06-14	4,764.77	4,193.07	5,384.86	3,909.40	5,733.32	4,920.20
16-06-14	4,767.80	4,192.11	5,392.57	3,906.58	5,743.79	4,912.81
17-06-14	4,770.84	4,191.16	5,400.25	3,903.79	5,754.22	4,873.86
18-06-14	4,773.87	4,190.25	5,407.91	3,901.04	5,764.62	4,902.50
19-06-14	4,776.91	4,189.35	5,415.55	3,898.33	5,774.99	4,879.49



Tabel Hasil Peramalan (Lanjutan)						
20-06-14	4,779.95	4,188.48	5,423.17	3,895.65	5,785.32	4,856.37
23-06-14	4,782.98	4,187.64	5,430.77	3,893.01	5,795.62	4,842.22
24-06-14	4,786.02	4,186.82	5,438.35	3,890.41	5,805.89	4,839.11
25-06-14	4,789.06	4,186.02	5,445.91	3,887.84	5,816.12	4,861.76
26-06-14	4,792.11	4,185.24	5,453.45	3,885.30	5,826.33	4,833.56
27-06-14	4,795.15	4,184.49	5,460.97	3,882.79	5,836.51	4,872.44
30-06-14	4,798.20	4,183.75	5,468.47	3,880.32	5,846.66	4,838.11
01-07-14	4,801.24	4,183.04	5,475.95	3,877.88	5,856.78	4,877.77
02-07-14	4,804.29	4,182.35	5,483.42	3,875.47	5,866.87	4,880.07
03-07-14	4,807.34	4,181.68	5,490.87	3,873.09	5,876.93	4,904.91
04-07-14	4,810.39	4,181.02	5,498.30	3,870.74	5,886.97	4,880.61
07-07-14	4,813.44	4,180.39	5,505.71	3,868.42	5,896.98	4,900.48
08-07-14	4,816.49	4,179.78	5,513.11	3,866.12	5,906.97	4,987.50
10-07-14	4,819.55	4,179.19	5,520.49	3,863.86	5,916.93	5,009.84
11-07-14	4,822.60	4,178.61	5,527.85	3,861.62	5,926.86	5,083.37
14-07-14	4,825.66	4,178.05	5,535.20	3,859.41	5,936.78	5,004.63
15-07-14	4,828.71	4,177.52	5,542.54	3,857.23	5,946.66	4,985.71
16-07-14	4,831.77	4,176.99	5,549.86	3,855.08	5,956.53	5,051.45
17-07-14	4,834.83	4,176.49	5,557.16	3,852.95	5,966.37	5,093.04
18-07-14	4,837.90	4,176.00	5,564.45	3,850.84	5,976.19	5,042.43
21-07-14	4,840.96	4,175.53	5,571.73	3,848.76	5,985.99	5,051.72
22-07-14	4,844.02	4,175.08	5,578.99	3,846.71	5,995.76	5,101.56
23-07-14	4,847.09	4,174.64	5,586.24	3,844.68	6,005.52	5,052.88
24-07-14	4,850.15	4,174.22	5,593.47	3,842.68	6,015.25	5,055.35
25-07-14	4,853.22	4,173.82	5,600.70	3,840.69	6,024.96	5,070.75
04-08-14	4,856.29	4,173.43	5,607.90	3,838.74	6,034.65	5,059.15
05-08-14	4,859.36	4,173.06	5,615.10	3,836.80	6,044.33	5,089.04
06-08-14	4,862.43	4,172.70	5,622.29	3,834.89	6,053.98	5,079.53
07-08-14	4,865.50	4,172.36	5,629.46	3,833.00	6,063.61	5,023.37
08-08-14	4,868.58	4,172.03	5,636.62	3,831.13	6,073.23	5,031.63
11-08-14	4,871.65	4,171.71	5,643.77	3,829.28	6,082.82	5,029.07
12-08-14	4,874.73	4,171.41	5,650.90	3,827.46	6,092.40	5,088.57
13-08-14	4,877.81	4,171.13	5,658.03	3,825.65	6,101.96	5,105.66
14-08-14	4,880.89	4,170.86	5,665.14	3,823.87	6,111.51	5,135.80
15-08-14	4,883.97	4,170.60	5,672.24	3,822.11	6,121.03	5,119.13
18-08-14	4,887.05	4,170.35	5,679.34	3,820.36	6,130.54	5,105.97
19-08-14	4,890.13	4,170.12	5,686.42	3,818.64	6,140.03	5,116.46
20-08-14	4,893.21	4,169.91	5,693.49	3,816.93	6,149.51	5,126.52
21-08-14	4,896.30	4,169.70	5,700.55	3,815.25	6,158.97	5,150.06

Tabel Hasil Peramalan (Lanjutan)						
22-08-14	4,899.39	4,169.51	5,707.60	3,813.58	6,168.41	5,164.49
25-08-14	4,902.47	4,169.33	5,714.64	3,811.94	6,177.84	5,152.86
26-08-14	4,905.56	4,169.16	5,721.67	3,810.31	6,187.25	5,135.02
27-08-14	4,908.65	4,169.01	5,728.69	3,808.70	6,196.65	5,097.68
28-08-14	4,911.75	4,168.87	5,735.71	3,807.11	6,206.03	5,116.49
29-08-14	4,914.84	4,168.74	5,742.71	3,805.53	6,215.39	5,146.26
01-09-14	4,917.93	4,168.62	5,749.70	3,803.98	6,224.75	5,095.26
02-09-14	4,921.03	4,168.51	5,756.69	3,802.44	6,234.09	5,127.54
03-09-14	4,924.12	4,168.42	5,763.66	3,800.92	6,243.41	5,164.21
04-09-14	4,927.22	4,168.34	5,770.63	3,799.41	6,252.72	5,180.12
05-09-14	4,930.32	4,168.27	5,777.59	3,797.92	6,262.02	5,157.28
08-09-14	4,933.42	4,168.21	5,784.54	3,796.45	6,271.30	5,162.39
09-09-14	4,936.52	4,168.16	5,791.48	3,795.00	6,280.57	5,196.86
10-09-14	4,939.63	4,168.12	5,798.41	3,793.56	6,289.83	5,146.39
11-09-14	4,942.73	4,168.09	5,805.34	3,792.14	6,299.07	5,080.29
12-09-14	4,945.84	4,168.07	5,812.26	3,790.73	6,308.31	5,079.82
15-09-14	4,948.94	4,168.07	5,819.17	3,789.34	6,317.52	5,105.57
16-09-14	4,952.05	4,168.07	5,826.07	3,787.96	6,326.73	5,109.02
17-09-14	4,955.16	4,168.09	5,832.96	3,786.60	6,335.93	5,092.54
18-09-14	4,958.27	4,168.11	5,839.85	3,785.25	6,345.11	5,149.31
19-09-14	4,961.38	4,168.15	5,846.73	3,783.92	6,354.28	5,170.41
22-09-14	4,964.50	4,168.19	5,853.60	3,782.61	6,363.44	5,181.62
23-09-14	4,967.61	4,168.25	5,860.47	3,781.30	6,372.59	5,170.37
24-09-14	4,970.73	4,168.31	5,867.33	3,780.02	6,381.73	5,134.01
25-09-14	4,973.84	4,168.39	5,874.18	3,778.74	6,390.85	5,119.04
26-09-14	4,976.96	4,168.47	5,881.02	3,777.48	6,399.97	5,154.17
29-09-14	4,980.08	4,168.57	5,887.86	3,776.24	6,409.07	5,089.29
30-09-14	4,983.20	4,168.67	5,894.69	3,775.01	6,418.17	5,085.28
01-10-14	4,986.32	4,168.78	5,901.52	3,773.79	6,427.25	5,101.73
02-10-14	4,989.45	4,168.90	5,908.34	3,772.58	6,436.32	5,103.16
03-10-14	4,992.57	4,169.03	5,915.15	3,771.39	6,445.39	4,961.30
06-10-14	4,995.70	4,169.17	5,921.95	3,770.21	6,454.44	4,891.78
07-10-14	4,998.83	4,169.32	5,928.75	3,769.05	6,463.48	4,983.76
08-10-14	5,001.95	4,169.48	5,935.55	3,767.90	6,472.51	5,019.47
09-10-14	5,005.08	4,169.65	5,942.33	3,766.76	6,481.54	4,936.86
10-10-14	5,008.21	4,169.82	5,949.12	3,765.63	6,490.55	4,969.70
13-10-14	5,011.35	4,170.00	5,955.89	3,764.51	6,499.56	4,947.24
14-10-14	5,014.48	4,170.20	5,962.66	3,763.41	6,508.55	4,894.78
15-10-14	5,017.62	4,170.40	5,969.43	3,762.32	6,517.54	4,910.13

Tabel Hasil Peramalan (Lanjutan)						
16-10-14	5,020.75	4,170.61	5,976.19	3,761.24	6,526.52	4,957.34
17-10-14	5,023.89	4,170.82	5,982.94	3,760.18	6,535.48	4,939.52
20-10-14	5,027.03	4,171.05	5,989.69	3,759.12	6,544.44	5,020.14
21-10-14	5,030.17	4,171.28	5,996.43	3,758.08	6,553.40	5,021.90
22-10-14	5,033.31	4,171.52	6,003.17	3,757.05	6,562.34	5,008.50
23-10-14	5,036.45	4,171.77	6,009.90	3,756.03	6,571.27	5,053.65
24-10-14	5,039.59	4,172.03	6,016.63	3,755.03	6,580.20	5,081.76
27-10-14	5,042.74	4,172.29	6,023.35	3,754.03	6,589.12	5,045.09
28-10-14	5,045.89	4,172.57	6,030.07	3,753.04	6,598.03	4,990.81
29-10-14	5,049.03	4,172.85	6,036.78	3,752.07	6,606.93	4,971.82
30-10-14	5,052.18	4,173.14	6,043.49	3,751.11	6,615.82	5,056.19
31-10-14	5,055.33	4,173.43	6,050.20	3,750.15	6,624.71	5,035.26
03-11-14	5,058.48	4,173.73	6,056.89	3,749.21	6,633.59	5,063.23
04-11-14	5,061.64	4,174.04	6,063.59	3,748.28	6,642.46	5,060.20
05-11-14	5,064.79	4,174.36	6,070.28	3,747.36	6,651.32	5,041.64
06-11-14	5,067.94	4,174.69	6,076.96	3,746.45	6,660.18	5,038.06
07-11-14	5,071.10	4,175.02	6,083.64	3,745.55	6,669.03	5,007.20
10-11-14	5,074.26	4,175.36	6,090.32	3,744.66	6,677.87	4,959.48
11-11-14	5,077.42	4,175.70	6,096.99	3,743.79	6,686.71	4,942.09
12-11-14	5,080.58	4,176.06	6,103.66	3,742.92	6,695.53	5,019.75
13-11-14	5,083.74	4,176.42	6,110.32	3,742.06	6,704.36	5,030.92
14-11-14	5,086.90	4,176.78	6,116.98	3,741.21	6,713.17	5,027.62
17-11-14	5,090.07	4,177.16	6,123.64	3,740.37	6,721.98	5,026.57
18-11-14	5,093.23	4,177.54	6,130.29	3,739.54	6,730.78	5,031.15
19-11-14	5,096.40	4,177.93	6,136.94	3,738.72	6,739.57	5,080.57
20-11-14	5,099.57	4,178.32	6,143.58	3,737.91	6,748.36	5,102.51
21-11-14	5,102.74	4,178.72	6,150.22	3,737.11	6,757.14	5,061.77
24-11-14	5,105.91	4,179.13	6,156.86	3,736.32	6,765.92	5,074.98
25-11-14	5,109.08	4,179.54	6,163.49	3,735.54	6,774.69	5,112.50
26-11-14	5,112.25	4,179.96	6,170.12	3,734.77	6,783.45	5,085.80
27-11-14	5,115.43	4,180.39	6,176.75	3,734.00	6,792.21	5,094.34
28-11-14	5,118.60	4,180.82	6,183.37	3,733.25	6,800.96	5,111.86
01-12-14	5,121.78	4,181.26	6,189.99	3,732.51	6,809.70	5,114.03
02-12-14	5,124.96	4,181.71	6,196.60	3,731.77	6,818.44	5,126.24
03-12-14	5,128.14	4,182.16	6,203.21	3,731.04	6,827.18	5,137.02
04-12-14	5,131.32	4,182.62	6,209.82	3,730.32	6,835.90	5,124.70
05-12-14	5,134.50	4,183.09	6,216.43	3,729.61	6,844.63	5,132.85
08-12-14	5,137.68	4,183.56	6,223.03	3,728.91	6,853.34	5,146.27
09-12-14	5,140.87	4,184.03	6,229.63	3,728.22	6,862.06	5,100.32

Tabel Hasil Peramalan (Lanjutan)						
11-12-14	5,144.05	4,184.51	6,236.22	3,727.54	6,870.76	5,072.46
12-12-14	5,147.24	4,185.00	6,242.81	3,726.86	6,879.46	5,113.66
15-12-14	5,150.43	4,185.50	6,249.40	3,726.20	6,888.16	5,125.99
16-12-14	5,153.62	4,186.00	6,255.99	3,725.54	6,896.85	5,068.74
17-12-14	5,156.81	4,186.50	6,262.57	3,724.89	6,905.53	4,980.12
18-12-14	5,160.00	4,187.02	6,269.15	3,724.24	6,914.21	4,996.10
19-12-14	5,163.20	4,187.53	6,275.73	3,723.61	6,922.89	5,095.39

## LAMPIRAN 2. LISTING PROGRAM

### Autoregressive Integrated Moving Average

```
# box-jenkins methodology
#####

# required libraries
#####

library(forecast)
library(fpp)
library(quantmod)

# download data
#####

getSymbols("^JKSE", from = "2010-01-01", to = "2014-12-25")
colnames(JKSE) <- c("Open", "High", "Low", "Close", "Volume", "Adjusted")
JKSE <- JKSE[which(JKSE$Volume!=0), ]

ihsg <- JKSE$Adjusted
plot(ihsg)
dataihsg <- as.ts(ihsg)
split <- floor(length(dataihsg)*0.8)
traindata <- window(dataihsg, end=split) # traindata
testdata <- window(dataihsg, start=split+1) #testdata
plot(traindata)
plot(testdata)

# descriptive statistics
#####

dev.off()
par(mfrow=c(2,2))
plot(traindata, main="Harga Penutupan IHSG")
hist(traindata, nclass="FD", main="Histogram", xlab="IHSG")
qqnorm(traindata, ylab="Standardized Scores", xlab="Normal Scores", main="Normal Plot")
qqline(traindata)
par(mfrow=c(1,2))
acf(traindata, lag.max=100, main="Fungsi Autokorelasi (ACF)")
pacf(traindata, lag.max=100, main="Fungsi Autokorelasi Parsial (PACF)")
summary(traindata)
sd(traindata)
dev.off()

# step 1: model identification
#####

# Augmented Dickey-Fuller Test
# The null-hypothesis for an ADF test is that the data has unit root so are
nonstationary.
# So large p-values are indicative of nonstationarity,
# and small p-values suggest stationarity.
# Using the usual 5% threshold, p-value greater than 0.05 suggest nonstationarity.
adf.test(traindata, alternative="stationary")

# box-cox transformation
lambda_bc <- 0.5
traindata_bc <- BoxCox(traindata, lambda_bc)
plot(traindata_bc, main="Transformasi Box-Cox", xlab="IHSG")
# inverse box-cox transformation
```

```

traindata_ibc <- InvBoxCox(traindata_bc, lambda_bc)
plot(traindata_ibc, main="Inverse Transformasi Box-Cox", xlab="IHSG")

# differencing
diffdata = diff(traindata, ndiffs(traindata))
plot(diffdata, main="Diferensiasi d=1", ylab="IHSG")
adf.test(diffdata, alternative="stationary")

# correlogram
par(mfrow=c(1,2))
acf_diffdata <- acf(diffdata, lag.max=10, main="(a) ACF")
pacf_diffdata <- pacf(diffdata, lag.max=10, main="(b) PACF")
dev.off()

# step 2: model estimation
#####

step = length(testdata)

# auto arima
arimafit <- auto.arima(traindata, lambda=0.35)
print(arimafit)

# step 3: model diagnostics
#####

# parameter significance
print(arimafit)
print("p-values")
(1-pnorm(abs(arimafit$coef)/sqrt(diag(arimafit$var.coef))))*2
print("confidence interval")
confint(arimafit, level=0.95)

residu <- residuals(arimafit)
par(mfrow=c(2,1))
plot(residu, main="(a) Residual", ylab="")
acf(residu, main="(b) ACF Residual")
dev.off()

# Augmented Dickey-Fuller Test
adf.test(residu, alternative="stationary")

# Ljung-Box Test
Box.test(residu, lag=10, fitdf=5)
Box.test(residu, lag=10, fitdf=5, type="Lj")

# Residual Diagnostics
par(mfrow=c(1,2))
hist(residu, nclass="FD", main="(a) Histogram Residual", xlab="Residuals")
qqnorm(residu, main="(b) Normal Plot Residual")
qqline(residu)
print(kurtosis(residu))
print(skewness(residu))
dev.off()

# Kolmogorov-Smirnov Test
ks.test(residu, pnorm, mean(residu, trim=0.25), sd(residu))

# arima model
#####

drift <- rwf(traindata, drift=TRUE, h=step)
summary(drift)
plot(drift, main="Peramalan Random Walk", xlab="t")

```

```

lines(testdata)

arimafit <- auto.arima(traindata, lambda=0.35)
arimaforecast <- forecast(arimafit, h=step, level=c(80,95))
summary(arimaforecast)
plot(arimaforecast, main="Peramalan ARIMA(3,1,2)", xlab="t")
lines(testdata)

# accuracy evaluation on test set
#####

accuracy(drift, testdata)
accuracy(arimaforecast, testdata)

```

## Neural Network Autoregression

```

# nonlinear autoregression model
#####

# required libraries
#####

library(forecast)
library(quantmod)
library(neuralnet)
library(DMwR)
library(pracma)
library(fpp)

# download and process data
#####

getSymbols("^JKSE", from = "2010-01-01", to = "2014-12-25")
colnames(JKSE) <- c("Open", "High", "Low", "Close", "Volume", "Adjusted")
JKSE <- JKSE[which(JKSE$Volume!=0), ]

dataihsg <- JKSE$Adjusted

# nonlinear autoregression model
#####

# data input
dataihsg_detrend <- detrend(dataihsg)
dataihsg_norm <- scale(dataihsg)
dataihsg_detrend_norm <- scale(detrend(dataihsg))

# choose input
dataihsg_net <- dataihsg_norm

lag_1 <- lag(dataihsg_net, 1)
lag_2 <- lag(dataihsg_net, 2)
lag_3 <- lag(dataihsg_net, 3)

dataframeihsg <- as.data.frame(cbind(dataihsg_net, lag_1, lag_2, lag_3))
colnames(dataframeihsg) <- c("Adjusted", "Lag1", "Lag2", "Lag3")

traindata <- na.omit(dataframeihsg[1:798,])
testdata <- dataframeihsg[799:998,]

# train neuralnet
set.seed(1234)

```

```

form.in <- as.formula("Adjusted ~ Lag1 + Lag2 + Lag3")
neuralnetar_model <- neuralnet(formula = form.in, data = traindata, hidden="4")
plot(neuralnetar_model)

# neuralnetar_model
neuralnetar_model$model.list
head(neuralnetar_model$data)
neuralnetar_model$startweights
neuralnetar_model$weights
neuralnetar_model$result.matrix
neuralnetar_model$net.result

# model evaluation and residual diagnostics
#####

# confidence intervals
ci <- confidence.interval(neuralnetar_model, alpha=0.05)
ci$lower.ci
ci$upper.ci

# predict on traindata
compute_traindata <- compute(neuralnetar_model, traindata[2:4])
prediction_traindata <- unscale(compute_traindata$net.result, dataihsg_norm)
traindata$Adjusted <- unscale(traindata$Adjusted, dataihsg_norm)

# plot prediction traindata
plot(as.ts(traindata$Adjusted), type="l",
      main="Peramalan NAR(3)", ylab="Data Testing")
lines(as.ts(prediction_traindata), col="blue")

plot(traindata$Adjusted, prediction_traindata, main="R=0.9963", xlab="Target",
      ylab="Output")
m <- lm(prediction_traindata ~ traindata$Adjusted)
abline(m, col="red")
cor(prediction_traindata, traindata$Adjusted)

model_error <- traindata$Adjusted - prediction_traindata
plot(model_error, type="l", xlab="Dataset Training", ylab="Error", main="(a) Residual
NAR")
acf(model_error, main="(b) Autokorelasi Residual NAR")

adf.test(model_error, alternative="stationary")
kps.test(model_error)
Box.test(model_error)

hist(model_error, main="Histogram Residual NAR")
ks.test(model_error, pnorm, mean(model_error, trim=0.25), sd(model_error))

# predict on testdata
#####

compute_testdata <- compute(neuralnetar_model, testdata[2:4])
prediction_testdata <- unscale(compute_testdata$net.result, dataihsg_norm)
testdata$Adjusted <- unscale(testdata$Adjusted, dataihsg_norm)

# plot prediction testdata
plot(as.ts(testdata$Adjusted), type="l", ylim=c(4500, 5500),
      main="Peramalan NAR(3)", ylab="Data Testing")
lines(as.ts(prediction_testdata), col="blue")

# accuracy evaluation
#####

```



```

traindata_error <- traindata$Adjusted - prediction_traindata
traindataME <- mean(traindata_error)
traindataMAE <- mean(abs(traindata_error))
traindataRMSE <- sqrt(mean((traindata_error)^2))
traindataPE <- 100*(traindata_error)/traindata$Adjusted
traindataMPE <- mean(traindataPE)
traindataMAPE <- mean(abs(traindataPE))
traindata_accuracy <- data.frame(traindataRMSE, traindataMAE, traindataMPE,
traindataMAPE)
print(traindata_accuracy)

testdata_error <- testdata$Adjusted - prediction_testdata
testdataME <- mean(testdata_error)
testdataMAE <- mean(abs(testdata_error))
testdataRMSE <- sqrt(mean((testdata_error)^2))
testdataPE <- 100*(testdata_error)/testdata$Adjusted
testdataMPE <- mean(testdataPE)
testdataMAPE <- mean(abs(testdataPE))
testdata_accuracy <- data.frame(testdataRMSE, testdataMAE, testdataMPE, testdataMAPE)
print(testdata_accuracy)

```

(Halaman ini sengaja dikosongkan)

### LAMPIRAN 3. *OUTPUT* HASIL UJI STATISTIK

Hasil uji *Augmented* Dicky-Fuller IHSG.

```
Console D:/9110205441-tesis/R/Adit Forecast IHSG/ ➡
> adf.test(traindata, alternative="stationary")

Augmented Dickey-Fuller Test

data:  traindata
Dickey-Fuller = -2.9783, Lag order = 9, p-value = 0.1642
alternative hypothesis: stationary
```

Hasil Uji ADF Setelah Diferensiasi dan Transformasi.

```
Console D:/9110205441-tesis/R/Adit Forecast IHSG/ ➡
> adf.test(diffdata, alternative="stationary")

Augmented Dickey-Fuller Test

data:  diffdata
Dickey-Fuller = -8.9501, Lag order = 9, p-value = 0.01
alternative hypothesis: stationary
```

Hasil Uji Stasioneritas Residual ARIMA(3,1,2)

```
Console D:/9110205441-tesis/R/Adit Forecast IHSG/ ➡
> adf.test(residu, alternative="stationary")

Augmented Dickey-Fuller Test

data:  residu
Dickey-Fuller = -8.7908, Lag order = 9, p-value = 0.01
alternative hypothesis: stationary
```

Hasil Asumsi *White Noise* Residual ARIMA(3,1,2)

```
Console D:/9110205441-tesis/R/Adit Forecast IHSG/ ➡
> Box.test(residu, lag=10, fitdf=5, type="Lj")

Box-Ljung test

data:  residu
X-squared = 2.7417, df = 5, p-value = 0.7397
```

### Hasil Uji Normalitas Residual ARIMA(3,1,2)

```
Console D:/9110205441-tesis/R/Adit Forecast IHSG/ ↗
> ks.test(residu, pnorm, mean(residu, trim=0.25), sd(residu))

One-sample Kolmogorov-Smirnov test

data:  residu
D = 0.0683, p-value = 0.001155
alternative hypothesis: two-sided
```

### Hasil Uji Stasioneritas Residual NAR(3)

```
Console D:/9110205441-tesis/R/Adit Forecast IHSG/ ↗
> adf.test(model_error, alternative="stationary")

Augmented Dickey-Fuller Test

data:  model_error
Dickey-Fuller = -8.418, Lag order = 9, p-value = 0.01
alternative hypothesis: stationary
```

### Hasil Asumsi *White Noise* Residual NAR(3)

```
Console D:/9110205441-tesis/R/Adit Forecast IHSG/ ↗
> Box.test(model_error)

Box-Pierce test

data:  model_error
X-squared = 0.0229, df = 1, p-value = 0.8798
```

## DAFTAR PUSTAKA

- Adhikari, R., Agrawal, R.K. (2013), *An Introductory Study on Time Series Modeling and Forecasting*. First Edition, LAP LAMBERT Academic Publishing, Saarbrücken.
- Bisgaard, S., Kuhlaci, M. (2011), *Time Series Analysis and Forecasting by Example*, John Wiley & Sons, New Jersey.
- Bodie, Z., Kane, A., Marcus, A. (2014), *Investments*, Tenth Edition, McGraw-Hill, Berkshire.
- Bursa Efek Indonesia (2013), Indonesian Stock Exchange 2013 Annual Report, URL: <http://www.idx.co.id/en-us/home/aboutus/annualreport.aspx>.
- Defusco, R.A., McLeavey, D.W., Pinto, J.E. (2007), *Quantitative Investment Analysis*, Second Edition, John Wiley & Sons, New Jersey.
- Fama, E.F. (1965), "The Behavior of Stock-Market Price", The Journal of Business, Vol. 38 no. 1, Hal. 34–105.
- Fernandez-Rodriguez, F., Gonzalez-Martel, C., Sosvilla-Rivero, S. (2000). "On the profitability of technical trading rules based on artificial neural networks: Evidence from the Madrid Stock Market". Economics Letters Vol.69, Hal. 89-94.
- Gilmore, C.G., McManus, G.M. (2003), "Random-Walk and Efficiency Tests of Central European Equity Markets", Managerial Finance, Vol. 29, Hal. 42-61.
- Han, J., Kamber, M., Pi, K. (2011), *Data Mining Concepts and Techniques*, Third Edition, Morgan Kaufmann, Massachusetts.
- Hanke, J.E., Wichern, D. (2009), *Business Forecasting*, Ninth Edition, Pearson Education, New Jersey.
- Hedinata, C. (2008), "Aplikasi Jaringan Syaraf Tiruan Untuk Peramalan Saham: Sebuah Rivew Penelitian Terdahulu". Prosiding Seminar Nasional Manajemen Teknologi VII.
- Hyndman, R.J., Athanosopoulos, G. (2013), *Forecasting Principles and Practice*, URL: <https://www.otexts.org/fpp>.

- Hyndman, R.J., Khandakar, Y. (2008), "Automatic Time Series Forecasting: The Forecast Package for R", *Journal of Statistical Software*, Vol. 27, Issue 3.
- Khasei, M., Bijari, M. (2010), "An Artificial Neural Network (p,d,q) Model for Time Series Forecasting". *Expert Systems with Applications*, Vol. 37, Hal. 479-489.
- Kirkpatrick II, C., D., Dahlquist, J. (2011), *Technical Analysis: The Complete Reference for Financial Market Technicians*, Second Edition, Pearson Education, New Jersey.
- Lantz, B. (2013), *Machine Learning with R*, First Edition, Packt Publishing Ltd, Birmingham.
- Malkiel, B.G. (2003), "The Efficient Market Hypothesis and Its Critics", *Journal of Economic Perspectives*, Vol. 17, No. 1, Hal. 59-82.
- R Project For Statistical Computing,  
URL: <http://www.r-project.org/>.
- Sudirman, I.M.S.N, Darmayanti, A. (2014), "The Selection of the Best Estimation Model of the Composite Index on Stock Exchanges in Five ASEAN Countries using Box Jenkins Method", *Forum Manajemen Indonesia* 5, Vol. 2013, Issue 1, Hal. 39.
- Van Horne, J., Wachowicz, J.M. (2008), *Fundamentals of Financial Management*, Thirteenth Edition, Prentice Hall, Essex.
- Wuryandani, G. (2011), "The Behavior and Determinants of Stock Market Index in Indonesia". *Indonesian Capital Market Review*, Vol. 3, No. 2, Hal. 101.

## BIODATA PENULIS



Nama: Vincentius Iwan Primaditya

Alamat: JL. Dukuh Kupang XXVIII No. 32 Surabaya

Tempat/Tgl. Lahir: Surabaya/5 September 1977

Riwayat Pendidikan:

1984 - 1990, SDK Indriyasana 7 Surabaya

1990 - 1993, SMP Negeri 3 Surabaya

1994 - 1997, SMU Negeri 4 Surabaya

2005-2010, Universitas 45 Surabaya